

**JIANNE RAFAELA MAZZINI DE SOUZA**

**ANÁLISE E PREVISÃO DE SÉRIES TEMPORAIS DA EXPORTAÇÃO DE  
PRODUTOS FLORESTAIS BRASILEIROS UTILIZANDO A METODOLOGIA BOX-  
JENKINS E REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

Orientador: Márcio Lopes da Silva

**VIÇOSA – MINAS GERAIS  
2021**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade  
Federal de Viçosa - Campus Viçosa**

T

S729a  
2021 Souza, Jianne Rafaela Mazzini de, 1991-  
Análise e previsão de séries temporais da exportação de  
produtos florestais brasileiros utilizando a metodologia  
box-jenkins e redes neurais artificiais / Jianne Rafaela Mazzini  
de Souza. – Viçosa, MG, 2021.

1 dissertação eletrônica (74 f.): il. (algumas color.).

Orientador: Márcio Lopes da Silva.

Dissertação (mestrado) - Universidade Federal de Viçosa,  
Departamento de Engenharia Florestal, 2021.

Inclui bibliografia.

DOI: <https://doi.org/10.47328/ufvbbt.2021.278>

Modo de acesso: World Wide Web.

1. Box-Jenkins, Método. 2. Aprendizado do computador.  
3. Análise de séries temporais. 4. Economia florestal. I. Silva,  
Márcio Lopes da, 1964-. II. Universidade Federal de Viçosa.  
Departamento de Engenharia Florestal. Programa de  
Pós-Graduação em Ciência Florestal. III. Título.

CDO adapt. CDD 22. ed. 634.97221

Bibliotecário(a) responsável: Alice Regina Pinto CRB6 2523

JIANNE RAFAELA MAZZINI DE SOUZA

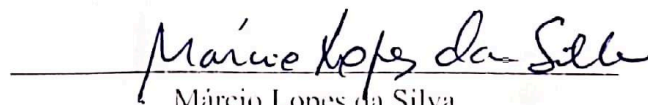
**ANÁLISE E PREVISÃO DE SÉRIES TEMPORAIS DA EXPORTAÇÃO DE  
PRODUTOS FLORESTAIS BRASILEIROS UTILIZANDO A METODOLOGIA BOX-  
JENKINS E REDES NEURAS ARTIFICIAIS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

APROVADA: 29 de setembro de 2021.

Assentimento:

  
Jianne Rafaela Mazzini de Souza  
Autora

  
Márcio Lopes da Silva  
Orientador

Este trabalho é dedicado à minha família e amigos, em especial à minha mãe Dhane Luzia de Souza (*in memoriam*), meu pai Jean Carlos da Silva Souza, meu avô Sebastião Ferreira de Souza (*in memoriam*) e minha avó Geralda Gomes de Jesus.

## AGRADECIMENTOS

Agradeço a Deus por me guiar e me sustentar ao longo desta caminhada.

Aos meus pais, Dhane Luzia de Souza (*in memoriam*) e Jean Carlos da Silva Souza, por sempre me apoiar, pelo amor incondicional e educação.

Ao meu orientador Márcio Lopes da Silva pela paciência, pelo ensinamento, disposição, amizade e, sobretudo, e por estar sempre disposto a ajudar e me apoiar.

Aos meus irmãos Jheny Kesley, Jean Carlos e Jeanine pelas conversas, amizade, companheirismo e carinho.

A minha sobrinha Pérola e meus afilhados Isac, Gabriel, Eric e Rebeca por alegrarem sempre os meus dias, me fazendo rir e chorar de saudade.

Ao Ivaldo da Silva Tavares Junior pelo convívio saudável, companheirismo, carinho, paciência e apoio em todos os momentos. Que me ajudou muito, acrescentando imprescindíveis contribuições neste trabalho.

Aos meus avós presentes e ausentes pelo carinho e orações. Em especial a minha avó Geralda que é um exemplo de força, dedicação e amor.

As minhas tias Divane, Sidriana e Kézia, pelo carinho e amor.

Aos amigos que UFV: Bruna, Gustavo, Vicente, Mara, Manu, Lucas, Yuri, Aguida, Cátia, Jeferson, Tulho, Ricardo pelo apoio e amizade fazendo deste período inesquecível.

Aos meus amigos da UFSJ, em especial a Irene, Reginaldo Arthur, Luciana, Livia e Gabi.

As estagiárias Larissa, Isabel e Luiza por toda parceria.

Aos professores Hélio Leite e Naisy Soares, que aceitaram o convite de compor a banca.

À Universidade Federal de Viçosa (UFV), pela excelência em ensino, técnico e humano e por todas as oportunidades que me trouxeram até aqui.

Ao Departamento de Engenharia Florestal (DEF) pela estrutura oferecida.

Ao Programa de Pós-Graduação em Ciência Florestal pela oportunidade de desenvolver esse trabalho, e em especial ao Alexandre e o professor Carlos pela disponibilidade, ajuda e dedicação.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pelo apoio financeiro – Código de Financiamento 001.

Aos amigos de vida e a todos que, de alguma forma, contribuíram para a realização desse trabalho.

A todos, meus mais sinceros agradecimentos!

“Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito. Não sou o que deveria ser, mas graças a Deus, não sou o que era antes.” (Marthin Luther King)

## RESUMO

SOUZA, Jianne Rafaela Mazzini de, M.Sc., Universidade Federal de Viçosa, setembro de 2021. **Análise e previsão de séries temporais da exportação de produtos florestais brasileiros utilizando a metodologia Box-Jenkins e Redes Neurais Artificiais.** Orientador: Márcio Lopes da Silva.

O Brasil é um dos principais países exportadores de produtos florestais madeireiros do mundo. Prever o futuro de variáveis associadas as exportações dos produtos florestais são muito importantes para tomada de decisão e um grande desafio. Desse modo, o objetivo do trabalho foi analisar e prever séries temporais das exportações de produtos florestais madeireiros brasileiros utilizando a técnica de Redes Neurais Artificiais (RNA) e a metodologia Box-Jenkins com os modelos ARIMA e ARIMAX. Os dados utilizados foram de históricos mensais das variáveis valor total exportado, em dólares americanos (US\$), quantidade exportada, em toneladas (t) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) de dois grupos de produtos florestais madeireiros, com informações desde janeiro do ano 1997 até dezembro do ano 2019. A etapa de análise das séries temporais consistiu na avaliação do comportamento das séries. A etapa de modelagem da previsão das séries temporais foi dividida em pré-processamento dos dados, predição das séries temporais, avaliação das RNA e dos modelos ARIMA e ARIMAX, previsão das séries temporais para os 12 meses do ano de 2019 e seleção da melhor técnica de previsão para as séries de cada grupo de produtos. Após a modelagem para previsão das séries temporais, uma matriz SWOT da utilização das técnicas foi construída. No resultado da previsão das séries temporais, os modelos ARIMA e ARIMAX e as RNA apresentaram boa performance. As RNA de forma individual foram mais precisas do que as RNA de forma generalizada e que os modelos ARIMA e ARIMAX, para cada grupo de produtos. A exceção foi a série valor exportado do grupo SH2-47, em que as RNA gerais obtiveram maior acurácia na previsão em comparação as RNA individuais. As topologias de RNA com a função de ativação exponencial, algoritmo Rprop e número de neurônios entre 16–30 são indicadas para previsão das séries temporais para os dois grupos de produtos florestais madeireiros. Estudos futuros podem ser conduzidos para melhorar a acurácia das previsões, como a utilização dos modelos da família ARIMA de forma híbrida com as RNA ou com outras técnicas de aprendizado de máquina.

Palavras-chave: Modelo ARIMA. Modelo ARIMAX. Aprendizado de máquinas. Modelo de previsão. Economia florestal.

## ABSTRACT

SOUZA, Jianne Rafaela Mazzini de, M.Sc., Universidade Federal de Viçosa, September, 2021. **Analysis and forecasting of time series of brazilian forest products exports using the Box-Jenkins methodology and Artificial Neural Networks.** Adviser: Márcio Lopes da Silva.

Brazil is one of the main exporting countries of wood forest products in the world. Forecasting the future of variables associated with exports of forest products is very important for decision making and a great challenge. Thus, the objective of the work was to analyze and forecast time series of exports of Brazilian wood forest products using the technique of Artificial Neural Networks (ANN) and the Box-Jenkins methodology with the ARIMA and ARIMAX models. The data used were from monthly histories of the variables total exported value, in US dollars (US\$), exported quantity, in tons (t) and unit value of one ton (US\$ t<sup>-1</sup>) of two groups of wood forest products, with information from January 1997 to December 2019. The time series analysis stage consisted of evaluating the behavior of the series. The time series forecast modeling step was divided into data pre-processing, time series prediction, ANN evaluation and ARIMA and ARIMAX models, time series forecast for the 12 months of 2019 and selection of the best forecasting technique for the series of each product group. After modeling to forecast the time series, a SWOT matrix of the use of the techniques was built. In the result of the forecast of the time series, the ARIMA and ARIMAX models and the ANN presented good performance. Individual ANN were more accurate than generalized ANN and that the ARIMA and ARIMAX models for each product group. The exception was the exported value series from group SH2-47, in which the general ANN had greater accuracy in forecasting compared to the individual ANN. ANN topologies with exponential activation function, Rprop algorithm and number of neurons between 16–30 are indicated for forecasting the time series for the two groups of wood forest products. Future studies can be conducted to improve the accuracy of forecasting, such as the use of models from the ARIMA family in a hybrid way with ANN or with other machine learning techniques.

Keywords: ARIMA model. ARIMAX model. Machine learning. Forecast model. Forest economy.

## LISTA DE ILUSTRAÇÕES

Figura 1- Esquema simplificado da metodologia geral do estudo com séries temporais da exportação dos produtos florestais madeireiros do Brasil. ....	18
Figura 2 - Esquema da metodologia dos modelos ARIMA e ARIMAX para previsão das séries temporais de cada grupo de produtos por abordagens.....	22
Figura 3 - Esquema da metodologia das Redes Neurais Artificiais para previsão das séries temporais de cada grupo de produtos. ....	27
Figura 4 - Séries temporais entre os anos de 1997 e 2019 do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47.....	32
Figura 5 - Séries temporais entre os meses dos anos de 1997 e 2019 do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47.....	33
Figura 6 - Gráficos da autocorrelação (ACF) das séries temporais do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47. ....	36
Figura 7 - Gráficos da autocorrelação parcial (PACF) das séries temporais do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47.....	37
Figura 8 - Séries temporais transformadas dos meses dos anos de 1997 e 2019 do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47.....	40
Figura 9 - Gráficos da autocorrelação (ACF) das séries temporais transformadas do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47. ....	40
Figura 10 - Gráficos da autocorrelação parcial (PACF) das séries temporais transformadas do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47. ....	41
Figura 11 - Valores observados e preditos das variáveis séries temporais preditas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando os modelos ARIMA para a abordagem 1. ....	44

Figura 12 - Valores observados e preditos das variáveis séries temporais preditas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando os modelos ARIMAX para a abordagem 2.....	45
Figura 13 - Análise gráfica dos resíduos das séries temporais preditas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando os modelos ARIMA.....	47
Figura 14 - Análise gráfica dos resíduos das séries temporais preditas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando os modelos ARIMAX. ....	48
Figura 15 - Gráficos da autocorrelação (ACF) dos resíduos das séries temporais preditas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando o modelo ARIMA para a abordagem 1. ....	49
Figura 16 - Gráficos da autocorrelação parcial (PACF) dos resíduos das séries temporais preditas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando o modelo ARIMA para a abordagem 1. ....	50
Figura 17 - Gráficos da autocorrelação (ACF) dos resíduos das séries temporais preditas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando o modelo ARIMAX para a abordagem 2.....	51
Figura 18 - Gráficos da autocorrelação parcial (PACF) dos resíduos das séries temporais preditas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) utilizando o modelo ARIMAX para a abordagem 2.....	51
Figura 19 - Gráficos da validação das Redes Neurais Artificiais para previsão séries temporais do valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) para os grupos SH2-44 e SH2-47 na abordagem 1.....	54
Figura 20 - Gráficos da validação das Redes Neurais Artificiais para previsão séries temporais do valor exportado (US\$) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) para os grupos SH2-44 e SH2-47 na abordagem 2. ....	55
Figura 21 - Gráficos dos valores previstos e observados das séries temporais do valor exportado (US\$) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) pelo modelo ARIMA e Redes Neurais Artificiais para os grupos SH2-44 e SH2-47 na abordagem 1. ....	58
Figura 22 - Gráficos dos valores previstos e observados das séries temporais do valor exportado (US\$) e valor unitário de uma tonelada (US\$ t <sup>-1</sup> ) pelo modelo ARIMAX e Redes Neurais Artificiais para os grupos SH2-44 e SH2-47 na abordagem 2. ....	59

## LISTA DE TABELAS

Tabela 1 - Descrição das seções, capítulos e produtos dos grupos selecionados. ....	19
Tabela 2 - Variáveis de entrada e preditas utilizadas nos modelos ARIMA e ARIMAX para previsão das séries temporais dos grupos de produtos nas abordagens.....	23
Tabela 3 - Variáveis utilizadas na modelagem com Redes Neurais Artificiais por grupo de produtos nas abordagens.....	28
Tabela 4 - Número de neurônios nas camadas de entrada, oculta e de saída utilizadas no treinamento das Redes Neurais Artificiais. ....	29
Tabela 5 - Estatística descritiva anual do valor exportado, quantidade exportada e valor unitário exportado (VU) do grupo SH2-44. ....	34
Tabela 6 - Estatística descritiva anual do valor exportado, quantidade exportada e valor unitário exportado (VU) do grupo SH2-47. ....	34
Tabela 7 - Correlação entre as variáveis das séries temporais. ....	35
Tabela 8 - Testes ADF e KPSS para estacionaridade da série temporais do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47.....	38
Tabela 9 - Testes ADF e KPSS para estacionaridade das séries temporais transformadas do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t <sup>-1</sup> ) dos grupos SH2-44 e SH2-47. ....	41
Tabela 10 - Modelos, parâmetros, estimativas e erro padrão do ajuste para a previsão das séries temporais de cada grupo de produtos por abordagem. ....	42
Tabela 11 - Estatísticas de precisão do ajuste dos modelos para a predição das séries temporais de cada grupo por abordagem.....	43
Tabela 12 - Teste Ljung-Box dos resíduos dos modelos para a previsão das séries temporais dos grupos SH2-44 e SH2-47 por abordagem. ....	46
Tabela 13 - Estatísticas de precisão do treinamento e validação das Redes Neurais Artificiais selecionadas para previsão das séries temporais. ....	53

Tabela 14 - Estatísticas de precisão da previsão das séries temporais com as Redes Neurais Artificiais e os modelos ARIMA e ARIMAX para os meses do ano de 2019..... 56

Tabela 15 - Matriz SWOT da aplicação dos modelos ARIMA/ARIMAX na previsão de séries temporais ..... 61

Tabela 16 - Matriz SWOT da aplicação da Redes Neurais Artificiais na previsão de séries temporais. .... 62

## SUMÁRIO

1 INTRODUÇÃO.....	14
2 OBJETIVOS.....	16
2.1 Objetivo geral .....	16
2.2 Objetivos específicos.....	16
3 MATERIAL E MÉTODOS.....	17
3.1 Esquema geral da metodologia.....	17
3.2 Coleta dos dados.....	19
3.3 Descrição e análise do comportamento das séries temporais .....	20
3.4 Modelagem das séries temporais.....	20
3.5 Metodologia dos modelos ARIMA e ARIMAX .....	20
3.5.1 Pré-processamento dos dados para os modelos ARIMA e ARIMAX.....	23
3.5.2 Ajuste dos modelos ARIMA e ARIMAX .....	24
3.5.3 Avaliação dos modelos ARIMA e ARIMAX.....	24
3.6 Metodologia das Redes Neurais Artificiais .....	25
3.6.1 Pré-processamento dos dados para as RNA .....	28
3.6.2 Treinamento e validação das RNA.....	29
3.6.3 Avaliação das RNA .....	30
3.7 Previsão das séries temporais .....	30
3.8 Análise SWOT das técnicas de previsão .....	30
4 RESULTADOS .....	31
4.1 Descrição das séries temporais .....	31
4.2 Modelagem com modelos ARIMA e ARIMAX .....	35
4.3 Modelagem com RNA.....	51
4.4 Previsão das séries temporais com os modelos ARIMA, ARIMAX e RNA .....	56
4.5 Matriz SWOT da técnica RNA e modelos ARIMA e ARIMAX .....	60
5 DISCUSSÃO.....	63

6 CONCLUSÃO.....	68
REFERÊNCIAS .....	69

## 1 INTRODUÇÃO

O Brasil possui aproximadamente 497,9 milhões de hectares (cerca de 59% do seu território) coberto por florestas naturais e plantadas, representando a segunda maior área de florestas do mundo, atrás apenas da Rússia (MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO, 2019). O Brasil se destaca como um dos principais países produtores de madeira. A madeira brasileira é exportada principalmente para países como a China (US\$ 3,48 bilhões), Estados Unidos (US\$ 2,80 bilhões), Itália (US\$ 724,81 milhões), Países Baixos (US\$ 722,54 milhões) e Argentina (US\$ 441,38 milhões) (SERVIÇO FLORESTAL BRASILEIRO, 2021). Dentre os produtos exportados no ano de 2019, a celulose foi o destaque, com o valor exportado de, aproximadamente, US\$ 7,5 bilhões, seguido do papel (US\$ 2 bilhões), serrados e compensados (US\$ 1,1 bilhão), e painéis de madeira e pisos laminados (US\$ 0,3 bilhão) (INDÚSTRIA BRASILEIRA DE ÁRVORES, 2020).

Devido a importância do Brasil no cenário mundial para o fornecimento de madeira e seus produtos derivados, entender e prever com precisão o comportamento das exportações e dos preços (ou valor unitário das exportações) dos produtos florestais madeireiros pode subsidiar o planejamento dos agentes desse mercado (produtores, vendedores, compradores, exportadores, players de mercado, investidores) e de políticas para o setor, pois necessitam de uma ferramenta eficiente para tomadas de decisão (SOARES et al., 2008, 2010b). Além disso, as previsões de variáveis associadas as exportações possibilitam estimar o impacto nos desenvolvimentos econômicos futuros no setor florestal do país. Para isso, a análise e modelagem de séries temporais de forma precisa são necessárias para minimizar os fatores aleatórios (erros) e as incertezas nos planejamentos futuros (BANAŚ; UTKIK-BANAŚ, 2021).

Uma das metodologias tradicionais mais utilizadas para previsão de séries temporais é a metodologia de Box-Jenkins aplicada ao modelo de média móvel integrada autorregressivo – ARIMA (BOX; JENKINS, 1970; CIPRA, 2020). A metodologia consiste em quatro etapas: identificação do modelo, estimação dos coeficientes, avaliação do modelo e previsão da série temporal (OHYVER; PUDJIHASTUTI, 2018). Esses procedimentos se aplicam a séries estacionárias, ou seja, séries temporais sem mudança sistemática na média e variância e cujos dados são normalmente distribuídos (GAIRAA et al., 2016; GULERYUZ, 2021; HASSAN, 2014). Os modelos ARIMA geralmente são construídos usando apenas as informações contidas nas séries. Assim, os modelos são construídos como funções lineares de valores passados da série ou erros aleatórios anteriores.

Apesar do modelo ARIMA apresentar resultados precisos em muitas aplicações (BANAŚ; UTRNIK-BANAŚ, 2021; GULERYUZ, 2021; SALMAN; KANIGORO, 2021; SHADAB; SAID; AHMAD, 2019; SOARES et al., 2008), técnicas alternativas vêm ganhando destaque com resultados ainda mais precisos, como é o caso das Redes Neurais Artificiais – RNA (BRAGA et al., 2021; CASTELLANO-MÉNDEZ et al., 2004; FANOODI; MALMIR; JAHANTIGH, 2019; YIP; FAN; CHIANG, 2014).

As RNA têm sido amplamente utilizadas para modelar séries temporais em várias áreas da economia florestal e ambiental, como na previsão da emissão de gases de efeito estufa na produção de eletricidade (BAKAY; AĞBULUT, 2021), previsão do preço da lenha (KOUTROUMANIDIS; IOANNOU; ARABATZIS, 2009), previsão dos valores de produção de painéis de fibra de média densidade (KURT, 2019), previsão das quantidades de vendas de madeira (AKYŪZ, 2009) e previsão da segurança na gestão de oferta e demanda de empresas florestais (ZHAO; YUE, 2020). Contudo, estudos que utilizem essa técnica para previsão de séries temporais da exportação de produtos florestais madeireiros ainda são raros.

Desse modo, este estudo tem como hipótese de que o uso de técnicas alternativas (RNA) aumenta a acurácia das previsões de séries temporais de exportações de produtos florestais em relação aos modelos tradicionais (ARIMA).

## 2 OBJETIVOS

### 2.1 Objetivo geral

Analisar e prever séries temporais da exportação de produtos florestais madeireiros brasileiros utilizando a técnica de Redes Neurais Artificiais e a metodologia Box-Jenkins com os modelos ARIMA e ARIMAX.

### 2.2 Objetivos específicos

- Avaliar o comportamento das séries temporais da exportação dos principais produtos florestais madeireiros brasileiros;
- Gerar modelos utilizando as técnicas ARIMA, ARIMAX e Redes Neurais Artificiais para previsão das séries temporais do valor total, quantidade e o valor unitário das exportações de produtos florestais madeireiros brasileiros;
- Avaliar as melhores configuração/topologia de Redes Neurais Artificiais para previsão de séries temporais de produtos florestais madeireiros brasileiros;
- Comparar as técnicas estudadas e selecionar a mais adequada para previsão das séries temporais de produtos florestais madeireiros brasileiros;
- Construir e analisar as matrizes SWOT (*strengths*/forças, *weaknesses*/ fraquezas, *opportunities*/oportunidades e *threats*/ameaças) da utilização das técnicas ARIMA, ARIMAX e Redes Neurais Artificiais para previsão de séries temporais.

### 3 MATERIAL E MÉTODOS

#### 3.1 Esquema geral da metodologia

A metodologia utilizada neste estudo foi dividida em três etapas principais: 1) análise das séries temporais da exportação dos produtos florestais madeireiros; 2) modelagem para previsão das séries com a metodologia Box-Jenkins (modelos ARIMA e ARIMAX) e Redes Neurais Artificiais (RNA) e; 3) construção e análise da matriz SWOT da aplicação do modelo ARIMA, ARIMAX e RNA na previsão de séries temporais.

A etapa de análise das séries temporais consistiu na avaliação do comportamento das séries das variáveis valor total exportado, em dólares americanos (US\$), quantidade dos produtos exportados, em toneladas (t) e valor unitário de uma tonelada exportada (US\$ t<sup>-1</sup>) de grupos de produtos florestais.

A etapa de modelagem da previsão das séries temporais foi dividida em pré-processamento dos dados, predição das séries temporais, avaliação das RNA e dos modelos ARIMA e ARIMAX, previsão das séries temporais e seleção da melhor técnica de previsão para as séries de cada grupo de produtos estudados no presente estudo.

Após a modelagem para previsão das séries temporais, uma matriz SWOT da utilização das técnicas foi construída. Essa matriz foi utilizada para identificar e avaliar as forças, oportunidades, fraquezas e ameaças da aplicação das RNA e dos modelos ARIMA e ARIMAX para previsão de séries temporais de produtos florestais. O esquema simplificado da metodologia geral deste estudo é observado na Figura 1.

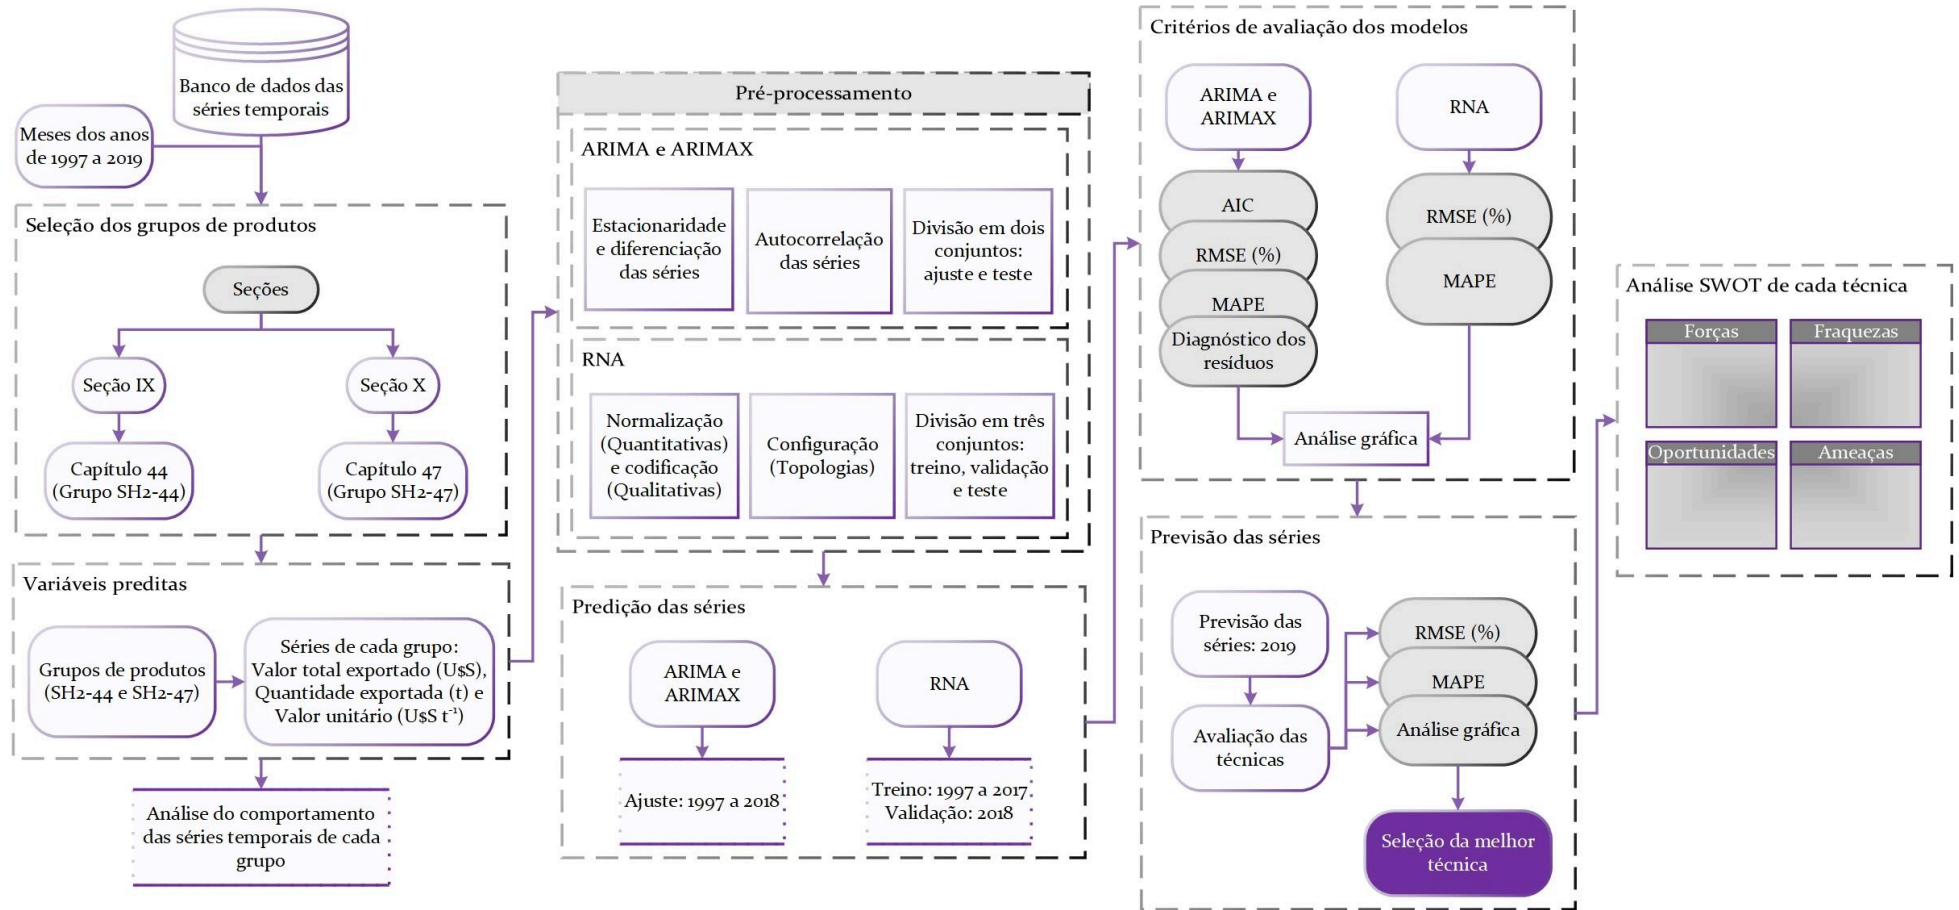


Figura 1- Esquema simplificado da metodologia geral do estudo com séries temporais da exportação dos produtos florestais madeireiros do Brasil.

### 3.2 Coleta dos dados

Os dados utilizados no presente estudo são de históricos mensais das exportações de dois grupos de produtos florestais madeireiros brasileiros (SH2-44 e SH2-47), com informações desde janeiro do ano 1997 até dezembro do ano 2019. Os dados foram baixados no formato “.xlsx” no site Comex Stat em um sistema para consultas, extração de dados e estatísticas do comércio exterior brasileiro do Ministério da Economia, no endereço <http://comexstat.mdic.gov.br>.

A nomenclatura dos grupos de produtos florestais foi definida de acordo com o Sistema Harmonizado de Designação e de Codificação de Mercadorias (SH), que é um método internacional de classificação de mercadorias formado por 21 seções e 96 capítulos (SH2). A escolha das seções e capítulos para estudo foi realizada considerando aqueles que geraram o maior valor total exportado e quantidade exportada de produtos florestais madeireiros. Sendo assim, os grupos de produtos desse estudo foram formados pelos capítulos 44 e 47 das seções IX e X, respectivamente (Tabela 1).

Tabela 1 - Descrição das seções, capítulos e produtos dos grupos selecionados.

Grupo	Seção	Capítulo	Produtos
SH2-44	IX - Madeira, carvão vegetal e obras de madeira; Cortiça e suas obras; Obras de espartaria ou de cestaria.	44	Madeira, carvão vegetal e obras de madeira.
SH2-47	X - Pastas de madeira ou de outras matérias fibrosas celulósicas; Papel ou cartão para reciclar; Papel e suas obras.	47	Pastas de madeira ou de outras matérias fibrosas celulósicas; papel ou cartão para reciclar.

O banco de dados foi constituído de variáveis qualitativas e quantitativas da exportação dos produtos florestais madeireiros do Brasil. As variáveis qualitativas foram os meses de cada ano. As variáveis quantitativas foram os anos, valor total exportado, quantidade dos produtos exportados e valor unitário de uma tonelada de produto exportado.

O valor FOB (US\$) foi utilizado para representar a variável valor exportado no presente estudo. O valor FOB US\$ expressa o valor somente dos produtos em dólares americanos sob o Incoterm FOB (*Free on Board*). Dessa forma, o comprador assume o pagamento do frete, seguros e demais custos pós-embarque.

### 3.3 Descrição e análise do comportamento das séries temporais

As variáveis valor total exportado, quantidade dos produtos exportados e valor unitário de uma tonelada exportada foram utilizadas para formar as séries temporais para análise e modelagem da previsão em cada grupo de produtos. Os dados anuais e mensais dessas variáveis foram plotados em gráficos de linhas entre os anos de 1997 e 2019 para avaliar o comportamento das séries temporais. As seguintes estatísticas das variáveis foram analisadas: valor mínimo, valor médio, valor máximo, desvio padrão e correlação entre as variáveis.

### 3.4 Modelagem das séries temporais

A metodologia Box-Jenkins e as RNA foram utilizadas para a modelagem e previsão das séries temporais do valor total exportado, quantidade dos produtos exportados e valor unitário de uma tonelada por grupo de produtos florestais madeireiros (SH2-44 e SH2-47). O modelo univariado ARIMA e o modelo multivariado ARIMAX foram as técnicas utilizadas na metodologia Box-Jenkins. Todo processamento dos dados para a modelagem da previsão das séries com a técnica de RNA e os modelos ARIMA e ARIMAX foi realizado no *software* R, versão 3.5.2 (R Core Team, 2021).

Esta etapa de modelagem constituiu de duas abordagens. A abordagem 1 considerou apenas o tempo na modelagem, enquanto na abordagem 2 foram considerados o tempo e a quantidade exportada como variáveis de entrada. Nas seções 3.5 e 3.6 estão os esquemas e detalhamento da modelagem das séries com a metodologia Box-Jenkins (ARIMA e ARIMAX) e as RNA, respectivamente.

### 3.5 Metodologia dos modelos ARIMA e ARIMAX

A modelagem para previsão das séries temporais com os modelos *auto regressive integrated moving average* ARIMA e ARIMAX foi realizada por meio de várias etapas. Primeiramente, o pré-processamento dos dados foi realizado, na qual a estacionaridade das séries foi verificada com posterior transformação das séries não estacionárias. Em seguida, as autocorrelações das séries foram testadas e os dados foram divididos em ajuste e teste. Os ajustes dos modelos ARIMA e ARIMAX foram feitos para estimar os parâmetros. Já a avaliação dos modelos ocorreu com base nas estatísticas de precisão e o diagnóstico dos

resíduos. Por fim, o melhor modelo de cada variável predita por grupo de produtos nas abordagens foi utilizado na previsão das séries temporais.

O esquema da metodologia utilizada para obtenção dos modelos ARIMA e ARIMAX está na Figura 2. Nas subseções 3.5.1, 3.5.2 e 3.5.3 estão descritos com detalhamento todas as etapas da modelagem com os modelos ARIMA e ARIMAX, com exceção da previsão das séries temporais que está no tópico 3.7.

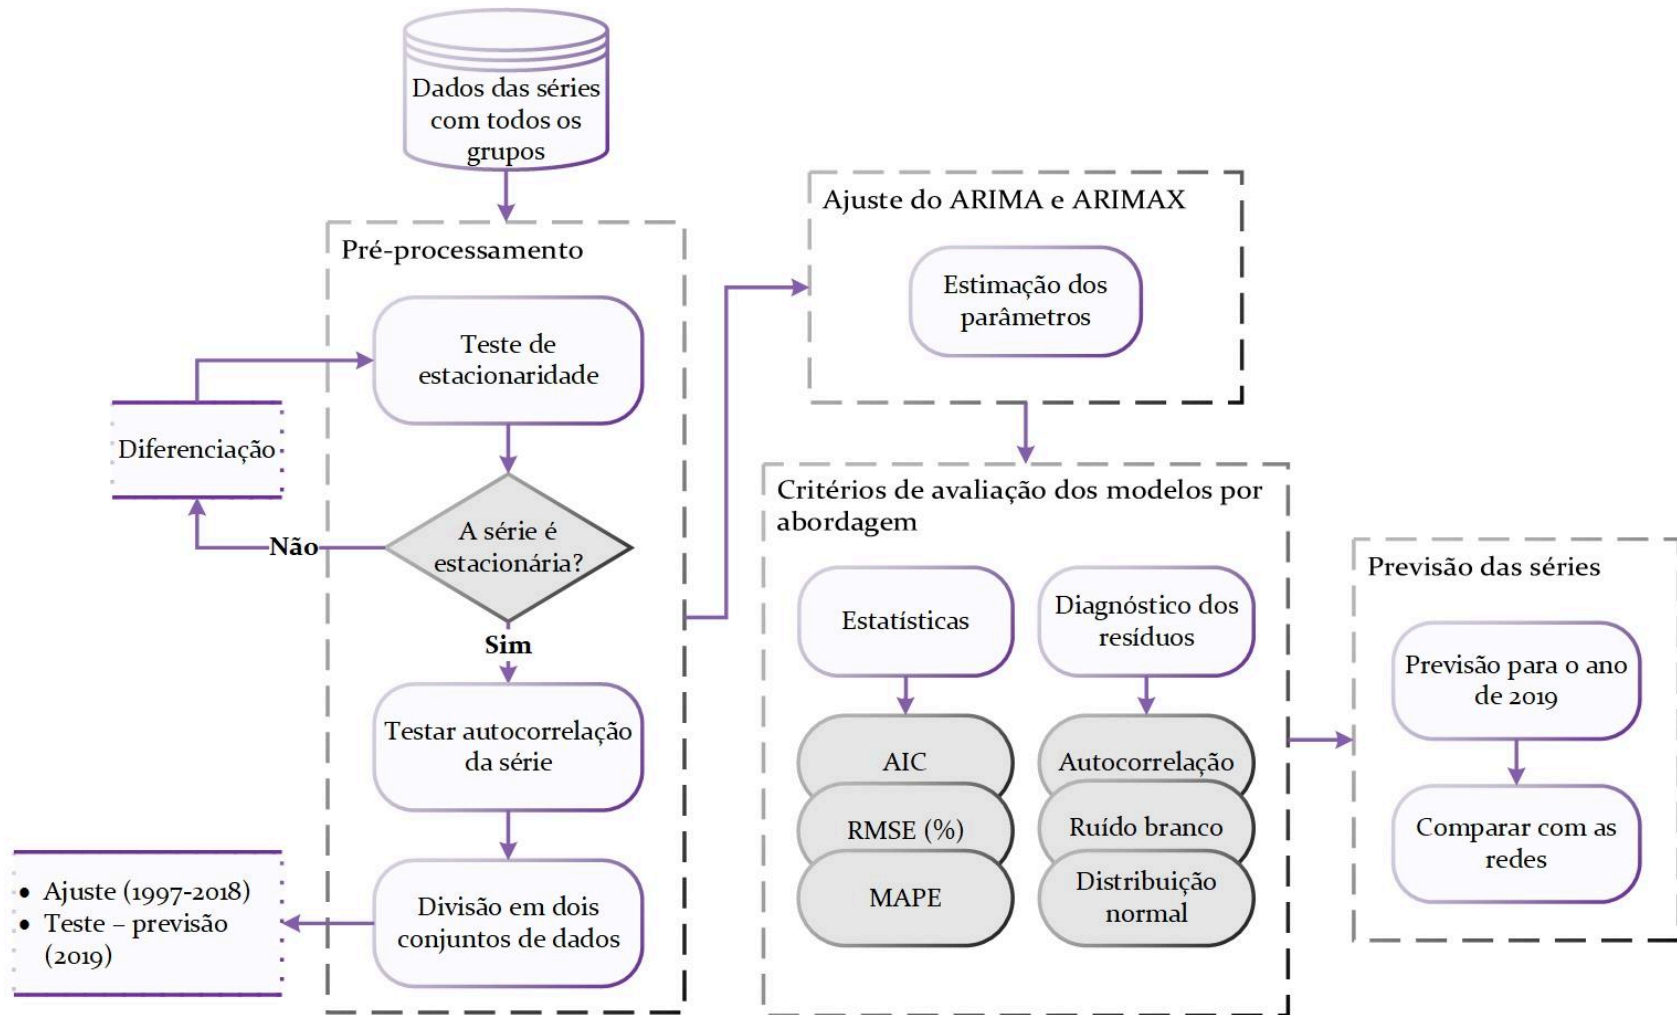


Figura 2 - Esquema da metodologia dos modelos ARIMA e ARIMAX para previsão das séries temporais de cada grupo de produtos por abordagens.

### 3.5.1 Pré-processamento dos dados para os modelos ARIMA e ARIMAX

A modelagem com a metodologia Box-Jenkins foi realizada com os modelos ARIMA na abordagem 1 e os modelos ARIMAX na abordagem 2. Uma descrição mais detalhada da metodologia Box-Jenkins pode ser encontrada no trabalho de Box e Jenkins (1970). As variáveis de entrada, variáveis de saída e modelos utilizados no processamento para a previsão das séries temporais por grupo de produtos nas abordagens estão na Tabela 2.

Tabela 2 - Variáveis de entrada e preditas utilizadas nos modelos ARIMA e ARIMAX para previsão das séries temporais dos grupos de produtos nas abordagens.

Abordagem	Modelo	Variáveis de entrada	Variável predita
1	ARIMA	Tempo (meses e anos)	Valor exportado (US\$)
		Tempo (meses e anos)	Quantidade exportada (t)
		Tempo (meses e anos)	Valor unitário de uma tonelada (US\$ t <sup>-1</sup> )
2	ARIMAX	Tempo (meses e anos)	Valor exportado (US\$)
		Quantidade exportada (t)	
		Tempo (meses e anos)	Valor unitário de uma tonelada (US\$ t <sup>-1</sup> )
		Quantidade exportada (t)	

A autocorrelação (ACF) e autocorrelação parcial (PACF) (ver detalhes das fórmulas em Soares et al. (2008)) das séries foi avaliada por meio das funções *acf* e *pacf* do pacote *stats*. A estacionaridade das séries temporais foi verificada utilizando os testes de raiz unitária Augmented Dickey-Fuller (ADF) e Kwiatkowski-Philips-Schmidt-Shin (KPSS) com as funções *ur.df* e *ur.kpss*, respectivamente, do pacote *urca* (PFAFF, 2008).

No teste KPSS a hipótese nula ( $H_0$ ) é a de não presença de uma raiz unitária na série, sendo assim a série estacionária. Em seguida, o teste retorna o menor número de diferenças necessárias para passar no teste no nível alfa. No teste de raiz unitária KPSS as hipóteses são:

$H_0$ : Não tem raiz unitária.

$H_1$ : Tem raiz unitária.

Assim, a estatística  $t$  calculada do teste tem que ser menor do que o valor crítico para que a hipótese nula seja aceita e concluir que a série é estacionária.

No teste ADF a hipótese nula é a presença de uma raiz unitária, dessa forma a série não é estacionária. Em seguida, o teste retorna o menor número de diferenças necessárias para falhar no teste no nível alfa. No teste de raiz unitária ADF, a interpretação é:

$H_0$ : Tem raiz unitária.

$H_1$ : Não tem raiz unitária.

Assim, se a estatística  $t$  do teste for negativa e menor do que o valor crítico a hipótese nula é rejeitada, com isso a série é estacionária.

As séries não estacionárias foram transformadas em estacionárias pelo método de diferenças sucessivas com a função *diff*. Para isso, primeiramente foi empregado o teste de raiz unitária com a função *ndiffs* para obter a quantidade de diferenciações necessárias para tornar a série estacionária. Posteriormente, a autocorrelação (ACF) e autocorrelação parcial (PACF) das séries transformadas foram analisadas.

As séries temporais foram divididas em dois conjuntos de dados, sendo eles: Ajuste e teste. O conjunto ajuste foi formado pelos meses dos anos de 1997 a 2018 com 264 observações, e o conjunto teste com os meses do ano de 2019 com 12 observações.

### 3.5.2 Ajuste dos modelos ARIMA e ARIMAX

Os ajustes dos modelos ARIMA e ARIMAX para obtenção dos parâmetros  $p$ ,  $d$  e  $q$  foram realizados com a função *auto.arima* do pacote *forecast* (HYNDMAN et al., 2021). A escolha dos parâmetros dessa função é realizada conforme o critério de informação Akaike (AIC), na qual é identificado o menor valor para o coeficiente que vai formar o melhor modelo do ponto de vista estatístico.

O parâmetro  $d$  é a quantidade de vezes que foi realizado a diferença entre os elementos da série até torná-la estacionária. Os parâmetros  $p$  e  $q$  foram obtidos pela análise da quantidade de picos gerados pelas funções ACF e PACF, respectivamente.

### 3.5.3 Avaliação dos modelos ARIMA e ARIMAX

Os modelos ajustados ARIMA e ARIMAX para cada variável predita por abordagem foram avaliados com base no diagnóstico dos resíduos e estatísticas de precisão das séries temporais.

O diagnóstico dos resíduos foi realizado pela verificação da não existência de autocorrelação residual, distribuição normal dos resíduos e presença de ruídos brancos. Para isso, a função *checkresiduals* do pacote *forecast* (HYNDMAN et al., 2021) foi utilizada para análise dos resíduos. A autocorrelação dos resíduos foi analisada por meio dos gráficos da função ACF. Para a verificação da normalidade da distribuição dos resíduos foi utilizado o histograma de erro e o gráfico dos resíduos em função do tempo. O teste de Ljung e Box (1978)

e a análise gráfica dos resíduos foram utilizados para avaliar a qualidade do ajuste e confirmar se os resíduos são ruídos branco. O teste Ljung-Box apresenta as seguintes hipóteses:

$H_0$ : Os resíduos são ruídos branco.

$H_1$ : Os resíduos não são ruídos branco.

Neste caso, se o  $p$ -valor for maior do que 0,05, ou seja,  $p > 0,05$  (não rejeita  $H_0$ ) os resíduos são ruídos brancos.

Os modelos gerados no ajuste de cada abordagem foram selecionados a partir da menor raiz quadrada do erro quadrático médio em porcentagem –  $RMSE$  (%) (Equação 1); menor erro percentual absoluto médio –  $MAPE$  (Equação 2); menor valor de critério de informação de Akaike –  $AIC$  (Equação 3); gráficos de dispersão dos resíduos (Equação 4) e; gráficos de dispersão dos valores observados e preditos.

$$RMSE (\%) = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \times \frac{100}{\bar{y}} \quad (1)$$

$$MAPE = \frac{1}{n} \times \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \times 100 \right| \quad (2)$$

$$AIC = -2\log L(\hat{\theta}) + 2(k) \quad (3)$$

$$Resíduos = \hat{y}_i - y_i \quad (4)$$

Em que:  $y_i$  = valor observado;  $\bar{y}$  = média aritmética dos valores observados; e  $\hat{y}_i$  = valor predito;  $L(\hat{\theta})$  = função suporte maximizada;  $k$  = número de parâmetros e;  $n$  = número de observações.

Após a seleção dos modelos que atenderam todos os critérios, o melhor modelo foi selecionado com base no princípio da parcimônia, em que os modelos mais simples e com menor número de parâmetros foram escolhidos.

### 3.6 Metodologia das Redes Neurais Artificiais

Para modelagem e previsão das séries temporais utilizando a técnica de Redes Neurais Artificiais (RNA) foi realizado, primeiramente, o pré-processamentos dos dados com a normalização, codificação e divisão dos dados, além da seleção das configurações testadas (algoritmos, funções de ativação, número de neurônios e camadas). Em seguida ocorreu o treinamento e validação das redes por grupo de produtos nas abordagens. Por fim, as melhores redes foram utilizadas para a previsão das séries temporais.

O esquema da metodologia utilizada na modelagem com RNA está na Figura 3. Nas próximas subseções do tópico 3.6 está descrito com detalhamento as etapas da modelagem com essa técnica, com exceção da previsão das séries temporais que está no tópico 3.7.

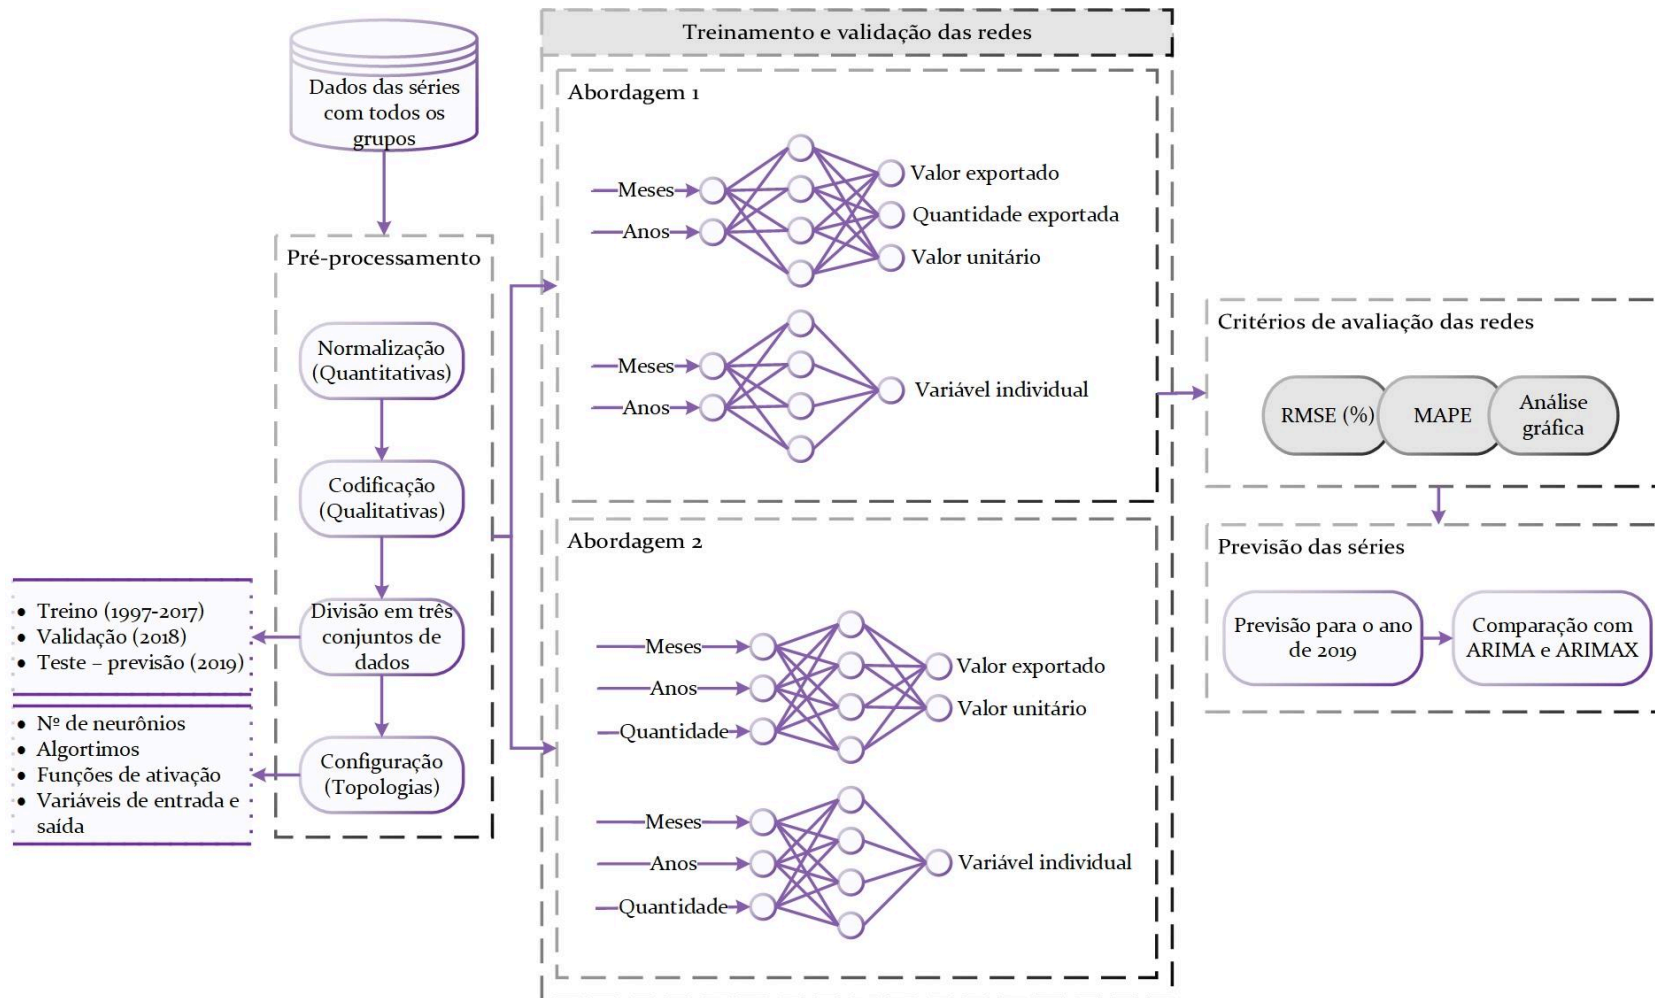


Figura 3 - Esquema da metodologia das Redes Neurais Artificiais para previsão das séries temporais de cada grupo de produtos.

### 3.6.1 Pré-processamento dos dados para as RNA

A modelagem utilizando a técnica de RNA foi realizada para obter redes treinadas para prever as séries temporais de forma individual e generalizada para cada grupo de produtos dentro das abordagens. O treinamento individual foi realizado apenas com uma variável na camada de saída para gerar a previsão das séries temporais de forma separada. Por outro lado, no treinamento generalizado as variáveis foram treinadas juntas na camada de saída da mesma RNA para previsão das séries temporais (Tabela 3).

Tabela 3 - Variáveis utilizadas na modelagem com Redes Neurais Artificiais por grupo de produtos nas abordagens.

Abordagem	Variáveis de entrada	Variáveis previstas (Variáveis de saída)
1	Tempo (Meses e anos)	Valor exportado (Individual)
		Quantidade exportada (Individual)
		Valor unitário de uma tonelada (Individual)
		Todas as variáveis (Geral)
2	Tempo (Meses e anos) e Quantidade exportada	Valor exportado (Individual)
		Valor unitário de uma tonelada (Individual)
		Todas as variáveis (Geral)

As variáveis quantitativas valor total exportado, quantidade dos produtos exportados e valor unitário de uma tonelada de produto exportado foram transformadas com a normalização linear, de forma a reescalonar a amplitude e magnitude das variáveis de entrada e saída para o intervalo de 0 a 1 (Equação 5):

$$v' = \frac{v - \min(v)}{\max(v) - \min(v)} (\max_{novo} - \min_{novo}) + \min_{novo} \quad (5)$$

Em que:  $\min(v)$ : menor valor da variável no banco de dados de treino;  $\max(v)$ : maior valor da variável no banco de dados treino;  $\max_{novo}$ : maior valor da normalização;  $\min_{novo}$ : menor valor da normalização;  $v'$ : valor da observação normalizada; e  $v$ : valor da observação não normalizada.

Desta forma, as previsões foram obtidas conforme o domínio das funções de ativação dos neurônios das camadas oculta e de saída com a normalização das variáveis quantitativas.

As variáveis qualitativas meses dos anos foram divididas em classes e codificadas em números binários (0 ou 1). Posteriormente, as séries temporais foram divididas em três conjuntos de dados, sendo eles: treino, validação e teste. O conjunto de treino compreendeu os

meses dos anos de 1997 a 2017 com 252 observações, enquanto que o conjunto de validação foi formado pelos meses do ano de 2018 com 12 observações. O conjunto de teste incluiu os meses do ano de 2019 com 12 observações.

### 3.6.2 Treinamento e validação das RNA

As RNA foram treinadas pelo método de aprendizado supervisionado com redes do tipo *perceptron* de múltiplas camadas, conhecidas como *Multilayer Perceptron* (MLP), com uma camada oculta. Os intervalos do número de neurônios na camada oculta das redes testadas foram definidos por meio de algumas simulações até não se obter ganhos em precisão (Tabela 4).

Tabela 4 - Número de neurônios nas camadas de entrada, oculta e de saída utilizadas no treinamento das Redes Neurais Artificiais.

Abordagem	Variáveis de entrada	Variáveis preditas	CE	CO	CS
1	Meses e Anos	Valor exportado			
		Quantidade exportada	13	8 a 30	1
		Valor unitário de uma tonelada			
		Todas as variáveis	13	8 a 31	3
2	Meses, Anos e Quantidade exportada	Valor exportado			
		Valor unitário de uma tonelada	14	8 a 30	1
		Valor unitário de uma tonelada			
		Todas as variáveis	14	8 a 33	2

Em que: CE – Camada de entrada; CO – Camada oculta; CS – Camada de saída.

Os algoritmos utilizados no treinamento das RNA foram o *Resilient Propagation* (Rprop) e o *Scaled Conjugate Gradient* (SCG). Já as funções de ativação testadas nos neurônios da camada oculta foram a exponencial, logística e tangente hiperbólica. Na camada de saída foi aplicada a função de ativação linear. Os pesos iniciais das RNA foram gerados aleatoriamente. O critério de parada das redes foi de 100 a 3.000 ciclos. Um total de 5.000 redes foram treinadas, sendo 2.500 para cada grupo de produtos.

A construção, treinamento e validação das redes foram implementadas com a função *mlp* do pacote *RSNNS* (BERGMEIR; BENITEZ, 2012). As redes obtidas com o treinamento foram aplicadas no conjunto de dados de validação formado pelos 12 meses do ano de 2018 para avaliar a qualidade do treino e selecionar a melhor configuração a ser utilizada no conjunto de teste.

### 3.6.3 Avaliação das RNA

As redes treinadas e validadas de cada abordagem foram avaliadas com base na raiz quadrada do erro quadrático médio em porcentagem – *RMSE (%)* (Equação 1); erro percentual absoluto médio – *MAPE* (Equação 2) e; gráficos de dispersão dos valores observados e previstos no ano de 2018.

As redes mais precisas no treinamento e validação de cada abordagem foram escolhidas a partir da menor *RMSE (%)*, menor *MAPE* e melhor comportamento gráfico de dispersão dos valores observados e previstos da validação.

## 3.7 Previsão das séries temporais

As melhores RNA na validação individual e generalizada, além do melhor modelo ARIMA e ARIMAX gerados nos ajustes foram considerados nesta etapa. A previsão das séries temporais foi realizada com a aplicação dos melhores resultados das técnicas no conjunto de dados teste, que compreende os 12 meses do ano de 2019.

A avaliação da previsão e comparação das técnicas foram feitas com base na raiz quadrada do erro quadrático médio em porcentagem – *RMSE (%)* (Equação 1); erro percentual absoluto médio – *MAPE* (Equação 2); e gráficos de dispersão dos valores observados e preditos. A melhor técnica de previsão das séries foi escolhida a partir do menor *RMSE (%)*, menor *MAPE* e melhor comportamento gráfico.

## 3.8 Análise SWOT das técnicas de previsão

O método SWOT foi utilizado para analisar as vantagens, desvantagens, detectar as capacidades e as vulnerabilidades da aplicação das técnicas ARIMA, ARIMAX e Redes Neurais Artificiais na modelagem da previsão de séries temporais de produtos florestais.

Para isso, uma matriz SWOT com quatro partes foi criada para cada técnica. Cada palavra que representa as siglas SWOT foi o tema para identificar as informações de cada parte, sendo elas: *strengths* (forças), *weaknesses* (fraquezas), *opportunities* (oportunidades) e *threats* (ameaças). No quadrante forças foram listados todas as forças e vantagens internas. Já nas fraquezas foram identificadas as principais desvantagens internas. No quadrante oportunidades foram elencados as forças e vantagens externas. Por fim, no quadrante ameaças foram listados os aspectos negativos externos.

Assim, a matriz SWOT possibilitou avaliar e comparar as técnicas (modelos ARIMA, ARIMAX e RNA) na previsão de séries temporais de produtos florestais. A construção da matriz do método SWOT foi realizada com base na pesquisa em artigos da literatura.

## **4 RESULTADOS**

### **4.1 Descrição das séries temporais**

O comportamento anual das variáveis valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47, são demonstrados nas curvas geradas pela soma dos valores anuais desde 1997 até 2019 (Figura 4). No grupo SH2-47, as séries de valor exportado e quantidade exportada foram similares com uma tendência de aumento positivo (crescente) ao longo dos anos. Já na série do valor unitário de uma tonelada não foi observada tendência de crescimento ou decréscimo dos valores, porém houve duas flutuações irregulares com um pico no ano de 2000 e um vale entre os anos de 2008 e 2010.

Em relação as séries anuais do grupo SH2-44, as séries de quantidade e valor total exportado apresenta uma leve tendência de crescimento. Entretanto, no final do ano de 2007 até 2009 houve uma queda acentuada dessas séries, com um aumento gradativo da série a partir desses anos. Após o ano de 2015, essas séries teve um crescimento mais acentuado da exportação. Para a série do valor unitário de uma tonelada não foi observada uma tendência evidente.

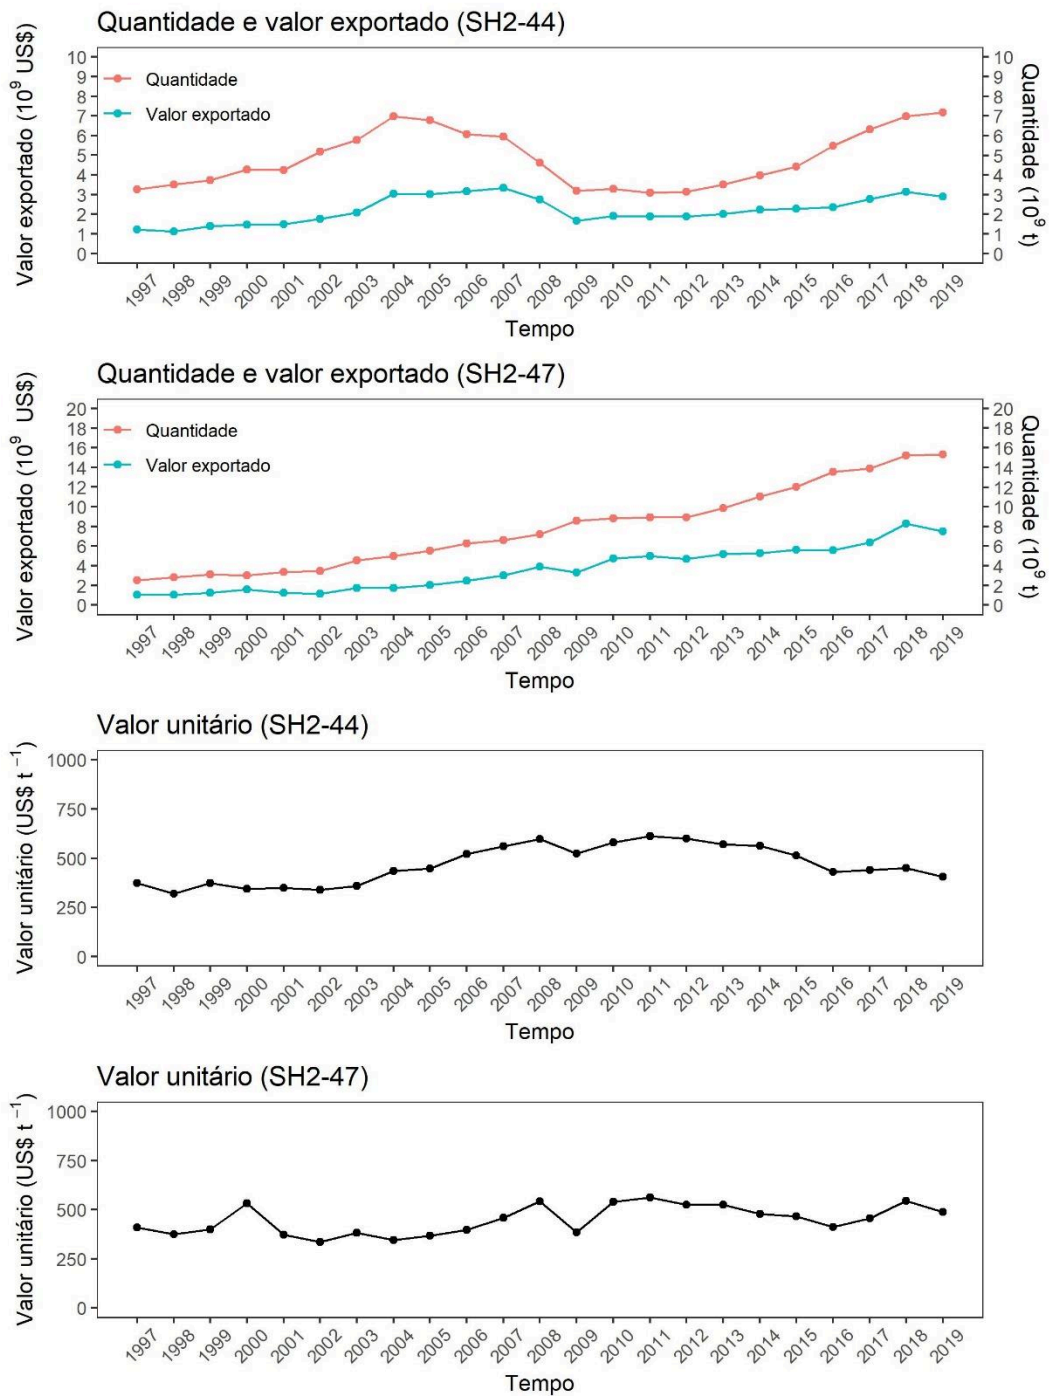


Figura 4 - Séries temporais entre os anos de 1997 e 2019 do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

O comportamento mensal das variáveis valor exportado, quantidade exportada e do valor unitário de uma tonelada dos grupos SH2-44 e SH2-47 ao longo dos meses dos anos, podem ser observadas nas curvas geradas pelos valores mensais desde 1997 até 2019 (Figura 5). A série temporal do valor exportado do grupo SH2-47 possui maior amplitude (16,1 milhões a 1 bilhão US\$) ao longo do tempo em relação ao grupo SH2-44 (75,7 milhões a 323,1 milhões

US\$). O mesmo aconteceu com a série da quantidade exportada, em que os grupos SH2-47 e SH2-44 possuem amplitudes variando de 40,90 mil a 1,67 milhão de toneladas e 172,20 mil a 776,50 mil toneladas, respectivamente. Por outro lado, a série valor unitário de uma tonelada do grupo SH2-44 apresentou maior quantidade de ruídos e maior amplitude dos valores (210,93 a 885,41 US\$ t<sup>-1</sup>) em comparação com o grupo SH2-47 (283,65 a 597,40 US\$ t<sup>-1</sup>).

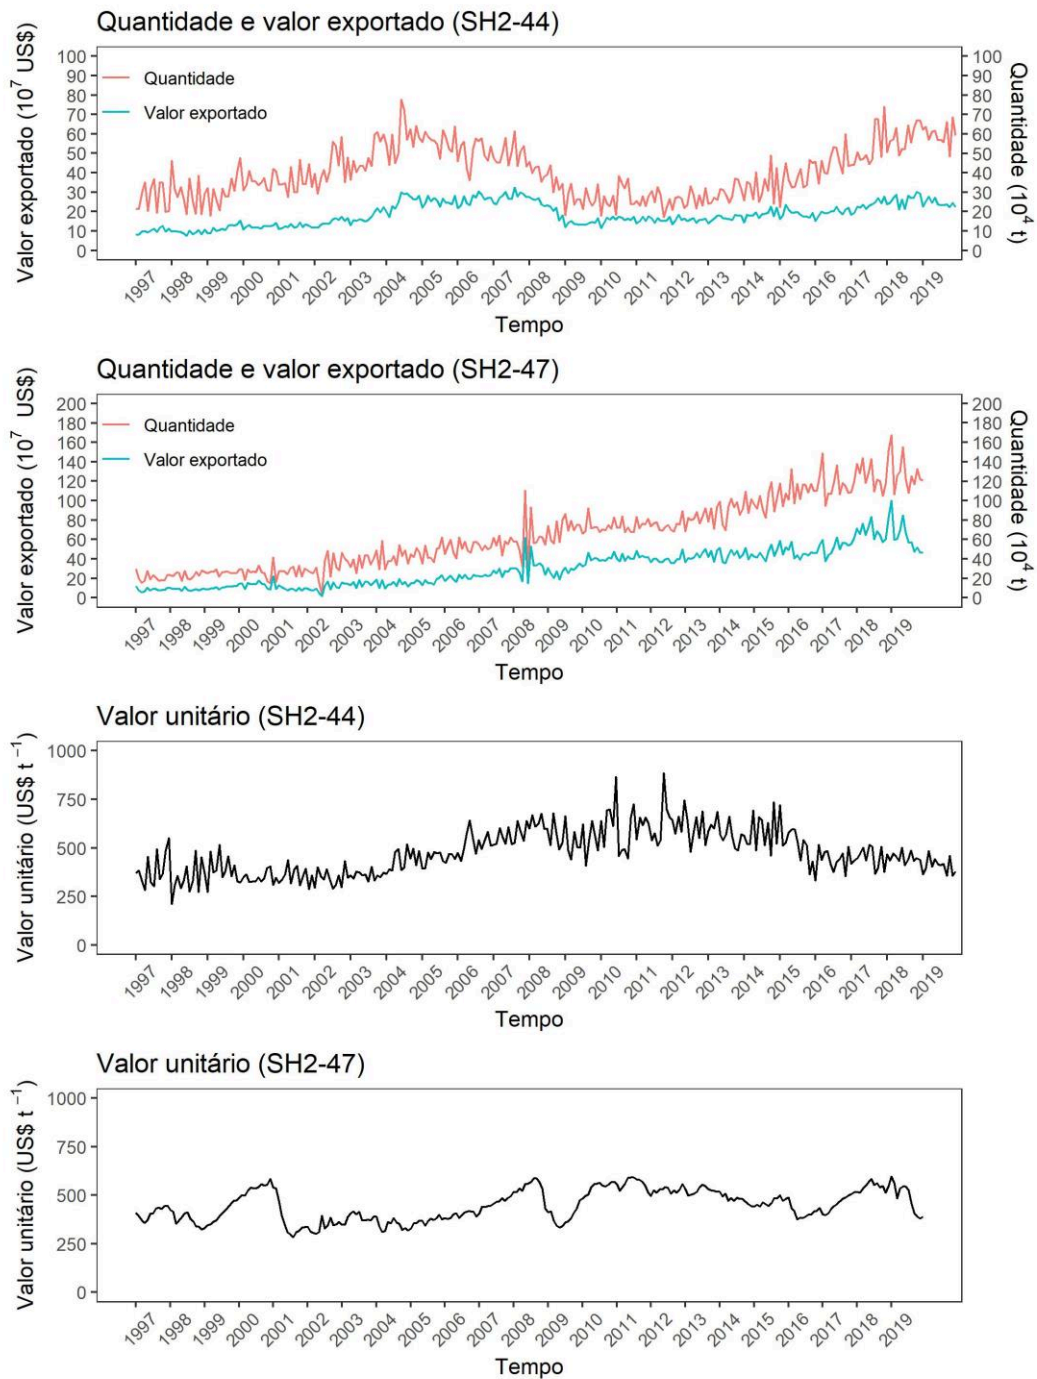


Figura 5 - Séries temporais entre os meses dos anos de 1997 e 2019 do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

A série quantidade exportada do grupo SH2-44 apresentou grandes variações dos valores de desvio padrão (DP) ao longo do tempo, sendo que os anos com maiores valores foram 2014, 2017, 2002 a 2004 e 1997 a 1999 (Tabela 5). A série valor unitário de uma tonelada apresentou maiores valores de DP entre os anos de 1997 a 1999 e 2008 a 2016. Já a série valor exportado não apresentou grandes variações no DP ao longo do tempo.

Tabela 5 - Estatística descritiva anual do valor exportado, quantidade exportada e valor unitário exportado (VU) do grupo SH2-44.

Grupo SH2 - 44												
Ano	Valor exportado (10 <sup>3</sup> US\$)				Quantidade exportada (10 <sup>3</sup> t)				VU (US\$ t <sup>-1</sup> )			
	Min	Méd	Máx	DP	Min	Méd	Máx	DP	Min	Méd	Máx	DP
1997	80155,2	101386,7	127806,0	14104,3	193,0	272,0	369,5	72,4	282,4	390,1	552,0	85,7
1998	75713,4	93757,2	107980,9	9568,1	185,8	292,5	462,0	85,9	210,9	340,3	486,0	78,8
1999	86582,0	115708,4	153285,7	19692,0	179,7	310,2	476,5	81,9	273,0	386,0	516,4	70,4
2000	108576,0	122930,3	141204,1	9051,5	307,0	356,0	420,2	39,5	309,0	347,4	405,6	29,3
2001	108831,2	123963,5	143475,0	10012,6	274,7	354,3	465,7	60,3	286,7	355,9	436,6	44,7
2002	116634,3	146823,5	173810,5	19271,5	291,7	431,9	585,2	91,1	290,9	346,6	433,6	45,0
2003	130621,1	173050,9	224036,6	29561,7	364,1	482,1	609,4	86,2	327,7	360,0	403,6	21,3
2004	171469,3	252865,8	300139,9	41088,1	439,7	581,8	776,5	101,0	366,6	437,8	518,1	54,3
2005	220058,5	252436,5	282530,1	20372,2	471,5	565,0	638,8	48,3	394,0	448,0	480,0	31,1
2006	218366,2	263183,0	304889,0	25988,7	361,7	506,0	578,3	68,5	432,7	525,3	640,9	57,7
2007	237266,9	277699,5	323109,4	23814,9	431,1	495,4	615,4	59,6	516,5	564,1	639,2	48,1
2008	153641,2	229421,5	274489,6	36714,4	299,1	384,1	456,9	50,4	493,0	597,5	679,2	61,6
2009	120397,5	139709,0	165720,6	11749,5	181,4	266,6	344,7	50,4	408,3	536,7	663,8	79,9
2010	114979,8	159437,6	174781,5	16959,8	179,9	274,7	383,0	68,3	444,7	606,4	864,9	130,5
2011	138879,3	158231,2	175163,0	12359,1	172,2	258,3	325,8	41,9	510,8	625,7	885,4	101,6
2012	134304,1	157232,9	183002,1	12186,2	209,3	262,0	330,7	40,7	478,9	609,6	745,1	77,2
2013	140582,8	166953,4	183979,9	13388,7	240,3	292,2	370,9	44,7	487,5	578,3	686,8	59,1
2014	144340,4	186832,2	225261,0	21913,6	240,4	332,4	489,6	78,9	460,1	578,8	735,4	89,7
2015	161086,5	189206,2	236261,4	20363,8	223,9	368,2	466,7	69,6	364,0	528,0	719,5	92,7
2016	151594,0	196786,6	224792,5	19638,7	343,4	457,4	599,0	71,4	332,5	436,7	517,4	59,3
2017	183749,3	231660,0	277381,0	27395,2	440,3	525,5	739,8	106,8	367,2	448,3	517,6	53,0
2018	211140,5	262005,5	300997,4	29437,6	488,6	581,3	672,1	65,1	410,2	451,3	502,5	26,4
2019	222627,5	242024,1	276033,3	17712,2	484,7	598,0	686,2	53,3	357,2	407,1	483,2	40,4

Em que: Min = Valor mínimo; Méd = Valor médio; Máx = Valor máximo e DP = Desvio padrão.

As séries valor total exportado e quantidade exportada do grupo SH2-47 obteve os maiores valores de DP nos anos de 2008, 2002 e a partir de 2013, com aumento gradativo até 2019. De outro modo, a série valor unitário de uma tonelada deste grupo obteve menor variação e menores valores de DP, com exceção dos anos de 1999, 2001, 2008, 2009, 2017 e 2019, os quais formaram picos e vales ao longo das séries (Tabela 6).

Tabela 6 - Estatística descritiva anual do valor exportado, quantidade exportada e valor unitário exportado (VU) do grupo SH2-47.

Ano	Valor exportado (10 <sup>3</sup> US\$)				Quantidade exportada (10 <sup>3</sup> t)				VU (US\$)			
	Min	Méd	Máx	DP	Min	Méd	Máx	DP	Min	Méd	Máx	DP
1997	57.359,8	85288	121668,8	18596	153,7	208,7	296,4	44,2	358,6	408,8	445,6	30,3
1998	67.670,7	87430	113213,9	12630	174,8	233,8	283,2	35,3	324,1	375,9	424,6	33,9

1999	83.786,5	103636	119839,6	13161	215,5	259,2	291,0	17,8	330,5	400,5	472,7	50,2
2000	85.691,5	133514	179639,3	28274	146,5	251,1	330,9	56,0	486,5	534,1	584,9	28,3
2001	67.689,8	103927	224186,8	41431	165,1	278,1	415,7	64,5	283,7	372,8	539,3	91,8
2002	16.152,5	96663	166135,2	41819	40,9	287,2	484,9	121,8	300,1	339,9	394,9	30,3
2003	101.230,0	145228	181713,7	23653	251,8	380,4	462,6	63,8	347,2	382,9	416,0	23,6
2004	92649,9	143530	191361,8	34354	291,8	415,7	587,0	95,8	310,5	345,1	390,5	26,2
2005	129643,0	169493	233013,3	30711	352,3	462,3	621,0	78,0	328,7	366,5	398,8	18,4
2006	164190,7	207000	238560,4	25866	404,3	520,5	621,4	68,0	377,3	398,2	416,2	15,1
2007	211346,3	252016	308308,0	33882	435,9	548,7	639,6	60,0	405,5	458,8	494,6	25,2
2008	147353,2	326425	616230,1	133596	262,9	601,3	1105,8	228,7	432,5	540,0	587,8	42,4
2009	190324,7	276098	354245,6	47371	558,9	715,5	861,2	96,6	332,3	385,8	472,4	42,7
2010	318711,5	396588	471546,0	43518	660,5	733,2	922,7	73,2	482,5	540,9	570,2	29,8
2011	376066,7	416802	484180,8	30469	674,5	742,5	837,7	59,3	515,9	562,2	592,5	26,0
2012	355586,3	392132	497325,7	37929	679,2	745,0	892,3	56,6	496,8	525,9	557,4	16,4
2013	365184,9	432101	504045,3	45326	684,5	823,2	937,6	81,6	497,0	524,9	554,6	17,8
2014	353582,1	441416	514074,9	52918	695,5	921,2	1095,6	115,2	443,0	480,0	518,9	21,3
2015	373944,7	466950	588124,0	61984	823,5	1003,6	1192,4	115,7	441,0	464,8	500,1	19,6
2016	390459,9	464607	575973,3	53501	970,2	1129,2	1327,6	104,3	374,8	411,7	488,0	31,1
2017	375247,4	529612	620541,4	74913	944,0	1157,9	1485,4	145,9	397,5	457,7	516,4	41,9
2018	574013,9	690273	832514,1	85624	1049,6	1269,6	1515,2	144,8	512,6	543,6	583,5	21,9
2019	462789,7	623092	1000559,3	161984	1066,0	1276,3	1674,9	176,7	378,9	484,8	597,4	77,6

Em que: Min = Valor mínimo; Méd = Valor médio; Máx = Valor máximo e DP = Desvio padrão.

Na tabela 7 estão apresentadas as correlações das variáveis das séries temporais dos grupos de produtos. As variáveis com maiores correlações foram valor exportado e quantidade exportada, com valores de 0,8159 e 0,9499 para os grupos SH2-44 e SH2-47, respectivamente. A variável valor unitário apresentou os menores valores de correlação com as demais variáveis em todos os grupos de produtos. Todas as correlações foram significativas no teste *t*, com *p*-valores menores que 0,05.

Tabela 7 - Correlação entre as variáveis das séries temporais.

Grupo	Variáveis das séries	Quantidade exportada	Valor exportado	Valor unitário
SH2-44	Quantidade exportada	1		
	Valor exportado	0,8159	1	
	Valor unitário	-0,4143	0,1482	1
SH2-47	Quantidade exportada	1		
	Valor exportado	0,9499	1	
	Valor unitário	0,2769	0,5247	1

## 4.2 Modelagem com modelos ARIMA e ARIMAX

Analisando os correlogramas da função de autocorrelação (ACF), as séries temporais mensais do valor exportado, quantidade exportada e do valor unitário de uma tonelada dos grupos SH2-44 e SH2-47 não apresentaram sazonalidade e ciclos (Figura 6). As séries do valor exportado, quantidade exportada e do valor unitário de uma tonelada apresentaram um padrão de redução suave dos picos. Porém, essas séries extrapolaram os limites das linhas tracejadas

em azul, mostrando que os dados são autocorrelacionados. A exceção foi a série valor unitário do grupo SH2-47, o qual apresentou padrão exponencial decrescente mais acentuado do ACF, contudo essa série também não ficou dentro dos limites das linhas em azul. Desse modo, esse resultado indica que as séries não são estacionárias.

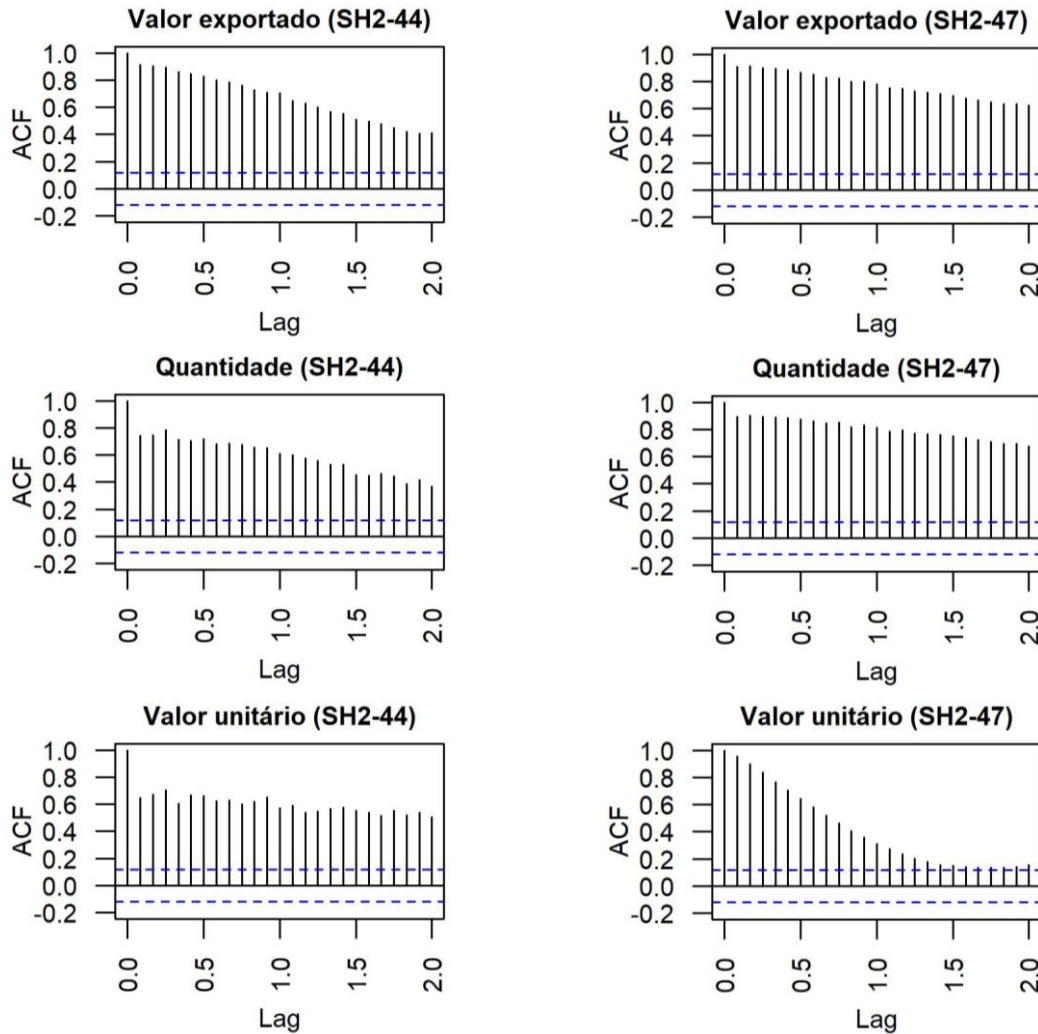


Figura 6 - Gráficos da autocorrelação (ACF) das séries temporais do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$  $t^{-1}$ ) dos grupos SH2-44 e SH2-47.

Nos gráficos da função de autocorrelação parcial (PACF) dos dados das séries temporais valor exportado, valor unitário de uma tonelada e quantidade exportada do grupo SH2-44 e valor exportado e quantidade exportada do grupo SH2-47, os picos iniciais alguns outros picos ao longo do PACF extrapolaram os limites do intervalo de confiança, não permitindo uma identificação clara da estrutura e da ordem dos modelos a serem utilizados (Figura 7).

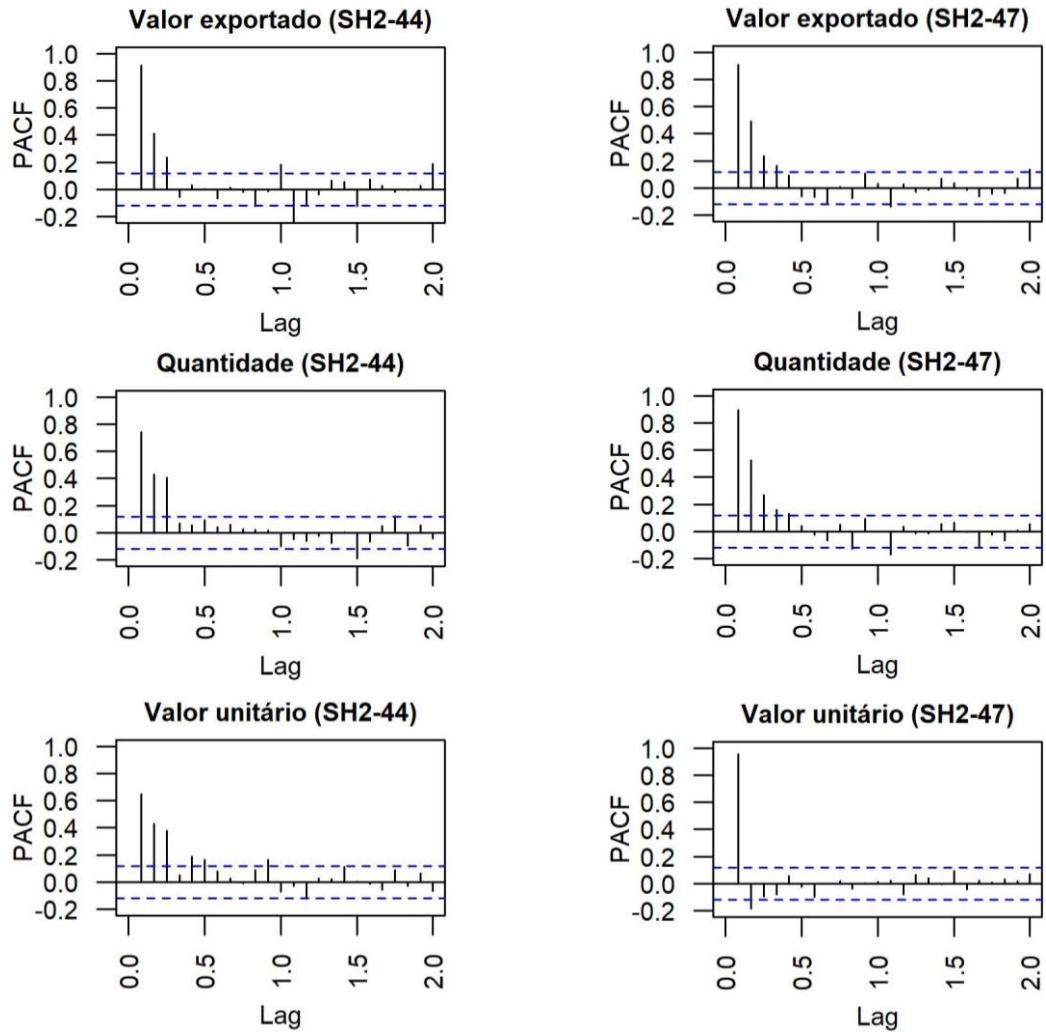


Figura 7 - Gráficos da autocorrelação parcial (PACF) das séries temporais do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

Os testes ADF e KPSS confirmaram a não estacionaridade das séries temporais do valor exportado, quantidade exportada e do valor unitário de uma tonelada exportada, com valores calculados maiores do que os valores críticos iguais a 0,463 e -1,95, respectivamente. Assim, a diferenciação dos dados das séries pelo método de diferença sucessiva foi necessária para essas séries se tornarem estacionárias (Tabela 8).

Tabela 8 - Testes ADF e KPSS para estacionaridade da série temporais do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

Variável	Grupo	ndif (KPSS)	ndif (ADF)	KPSS <sup>1</sup>	ADF <sup>2</sup>	p-valor
Valor exportado	SH2-44	1	1	1,388	-0,092	<0,05
	SH2-47	1	1	4,326	-0,615	<0,05
Quantidade exportada	SH2-44	1	1	0,621	-0,565	<0,05
	SH2-47	1	1	4,529	-0,172	<0,05
Valor unitário	SH2-44	1	1	2,028	-0,919	<0,05
	SH2-47	1	1	1,435	-0,482	<0,05

Em que: ndif = número de diferenciações necessárias. <sup>1</sup>Valor crítico da estatística KPSS igual a 0,463.

<sup>2</sup>Valor crítico da estatística ADF igual a -1,95.

As séries transformadas com uma diferenciação do valor exportado, quantidade exportada e do valor unitário de uma tonelada dos grupos SH2-44 e SH2-47 estão apresentadas na Figura 8. As séries após a transformação não apresentaram mais nenhuma tendência, com oscilações entre valores positivos e negativos e variâncias relativamente constantes.









Figura 8 - Séries temporais transformadas dos meses dos anos de 1997 e 2019 do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

Os gráficos da ACF e PACF das séries temporais transformadas mostram a maioria dos valores dentro do intervalo entre -1 a 1 e -0,60 a 0,15, respectivamente, com poucos picos extrapolando os limites das linhas tracejadas em azul. Sendo assim, os dados das séries transformadas com uma diferenciação não possuem autocorrelação e sazonalidade (Figuras 9 e 10).

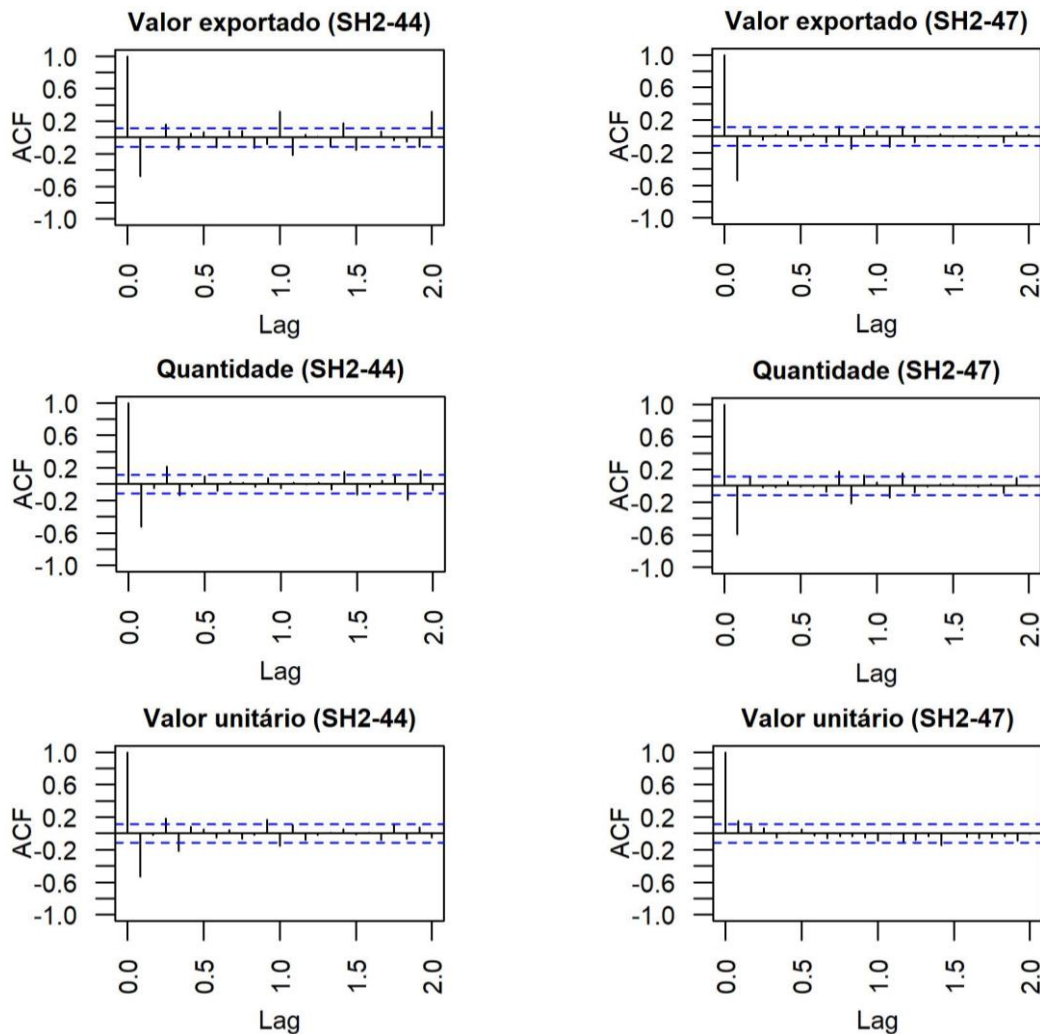


Figura 9 - Gráficos da autocorrelação (ACF) das séries temporais transformadas do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

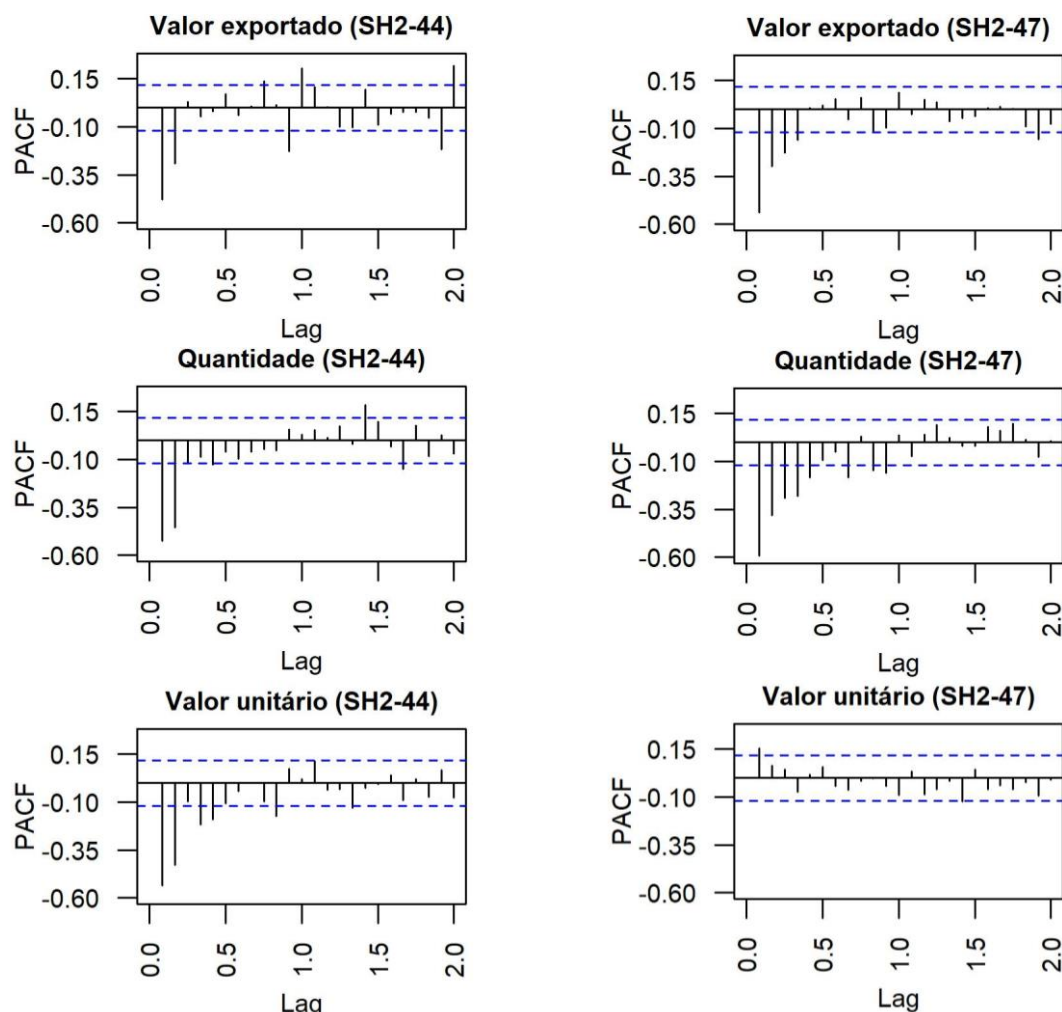


Figura 10 - Gráficos da autocorrelação parcial (PACF) das séries temporais transformadas do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

Os valores calculados nos testes ADF e KPSS das séries temporais transformadas foram menores que os valores críticos das estatísticas iguais a 0,463 e -1,95, respectivamente (Tabela 9). Desse modo, todas as séries temporais transformadas se tornaram estacionárias.

Tabela 9 - Testes ADF e KPSS para estacionaridade das séries temporais transformadas do valor exportado (US\$), quantidade exportada (t) e do valor unitário de uma tonelada exportada (US\$ t<sup>-1</sup>) dos grupos SH2-44 e SH2-47.

Variável	Grupo	KPSS <sup>1</sup>	ADF <sup>2</sup>	<i>p</i> -valor
Valor exportado	SH2-44	0,086	-19,064	<0,05
	SH2-47	0,031	-19,659	<0,05
Quantidade exportada	SH2-44	0,055	-23,483	<0,05
	SH2-47	0,031	-21,982	<0,05
Valor unitário	SH2-44	0,059	-22,803	<0,05
	SH2-47	0,045	-10,070	<0,05

<sup>1</sup>Valor crítico da estatística KPSS igual a 0,463 ( $\alpha = 5\%$ ). <sup>2</sup>Valor crítico da estatística ADF igual a -1,95 ( $\alpha = 5\%$ ).

Os melhores modelos ajustados para as variáveis das séries temporais por grupo de produtos nas abordagens estão contidos na Tabela 10, juntamente com seus respectivos parâmetros, estimativas e erro padrão dos parâmetros.

Tabela 10 - Modelos, parâmetros, estimativas e erro padrão do ajuste para a previsão das séries temporais de cada grupo de produtos por abordagem.

Abordagem	Variável predita	Grupo	Modelo	Parâmetros	Estimativas	Erro padrão
Abordagem 1	Valor exportado	SH2-44	ARIMA (2,1,0)	ar1	-0,6159	0,0592
				ar2	-0,2752	0,0593
		SH2-47	ARIMA (1,1,1)	ar1	-0,3605	0,0759
				mv1	-0,5621	0,0643
	Valor unitário	SH2-44	ARIMA (1,1,3)	ar1	-0,8679	0,0568
				mv1	-0,0111	0,0772
				mv2	-0,7723	0,0458
		SH2-47	ARIMA (1,1,3)	mv3	0,1481	0,0610
				ar1	0,9223	0,0271
				mv1	0,1680	0,0684
	Quantidade exportada	SH2-44	ARIMA (3,1,1)	mv2	0,2278	0,0709
				mv3	0,1302	0,0615
				ar1	-0,1031	0,1149
				ar2	-0,0272	0,1014
SH2-47		ARIMA (1,1,1)	ar3	0,1890	0,0848	
			mv1	-0,7387	0,0927	
			ar1	-0,1885	0,0679	
			mv1	-0,8060	0,0356	
Abordagem 2	Valor exportado	SH2-44	ARIMAX (2,1,0)	ar1	-0,6316	0,0603
				ar2	-0,2514	0,0603
		SH2-47	ARIMAX (0,1,2)	mv1	-0,2883	0,0607
				mv2	0,2295	0,0634
	Valor unitário	SH2-44	ARIMAX (5,1,0)	ar1	0,3957	0,0617
				ar2	0,2860	0,0650
				ar3	0,2155	0,0659
		SH2-47	ARIMAX (1,1,3)	ar4	-0,0992	0,0650
				ar5	0,1704	0,0613
				ar1	0,9270	0,0263
SH2-47	ARIMAX (1,1,3)	mv1	0,1632	0,0683		
		mv2	0,2373	0,0706		
		mv3	0,1171	0,0619		

Em que: ar = autorregressivo; mv = média móvel

Os modelos da abordagem 2 (ARIMAX) obtiveram maior precisão nas estimativas das variáveis valor exportado e valor unitário de uma tonelada exportada (US\$ t<sup>-1</sup>) em comparação aos modelos da abordagem 1 (ARIMA), com valores de *AIC* entre 2369,99 e 9562,35, *RMSE* (%) entre 4,67 e 8,23% e *MAPE* entre 3,66 e 8,12% (Tabela 11).

Tabela 11 - Estatísticas de precisão do ajuste dos modelos para a predição das séries temporais de cada grupo por abordagem.

Abordagem	Variável predita	Grupo	Modelo	AIC	RMSE (%)	MAPE
Abordagem 1	Valor exportado	SH2-44	ARIMA (2,1,0)	9589,37	10,85	8,45
		SH2-47	ARIMA (1,1,1)	10120,31	18,71	15,96
	Valor unitário	SH2-44	ARIMA (1,1,3)	3002,34	14,92	11,42
		SH2-47	ARIMA (1,1,3)	2369,69	4,69	3,66
	Quantidade exportada	SH2-44	ARIMA (3,1,1)	10262,94	17,90	15,13
		SH2-47	ARIMA (1,1,1)	-29,35	16,87	15,22
Abordagem 2	Valor exportado	SH2-44	ARIMAX (2,1,0)	9445,93	8,23	6,62
		SH2-47	ARIMAX (0,1,2)	9562,35	6,46	6,60
	Valor unitário	SH2-44	ARIMAX (5,1,0)	2831,54	10,44	8,12
		SH2-47	ARIMAX (1,1,3)	2369,99	4,67	3,66

Os gráficos com os valores observados e preditos das variáveis das séries temporais com os modelos ARIMA para a abordagem 1 e ARIMAX para a abordagem 2 podem ser observados nas Figuras 11 e 12, respectivamente. As predições das séries com o modelo ARIMA acompanharam as tendências dos dados observados, contudo, a maioria das oscilações e amplitudes foram menores do que as das séries originais. As predições da série valor unitário de uma tonelada do grupo SH2-47 com o modelo ARIMA foram bem próximas dos valores observados, acompanhando as oscilações e amplitudes dessa série. Para os modelos ARIMAX, as predições de todas as séries temporais e grupos acompanham de forma mais precisa as oscilações e amplitude das séries originais.



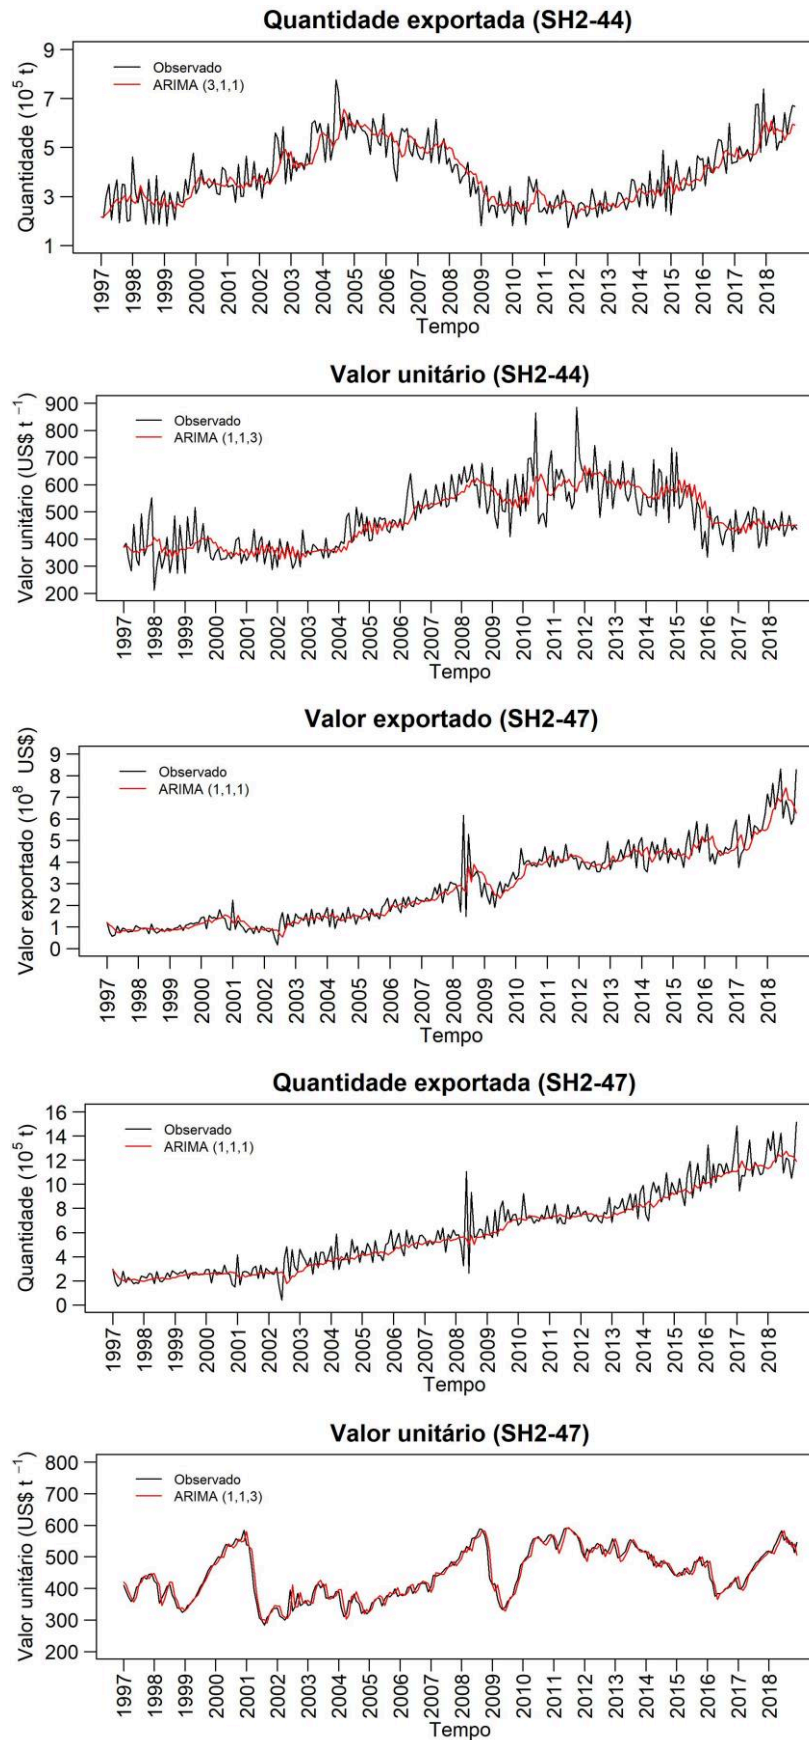


Figura 11 - Valores observados e preditos das variáveis séries temporais preditas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) utilizando os modelos ARIMA para a abordagem 1.

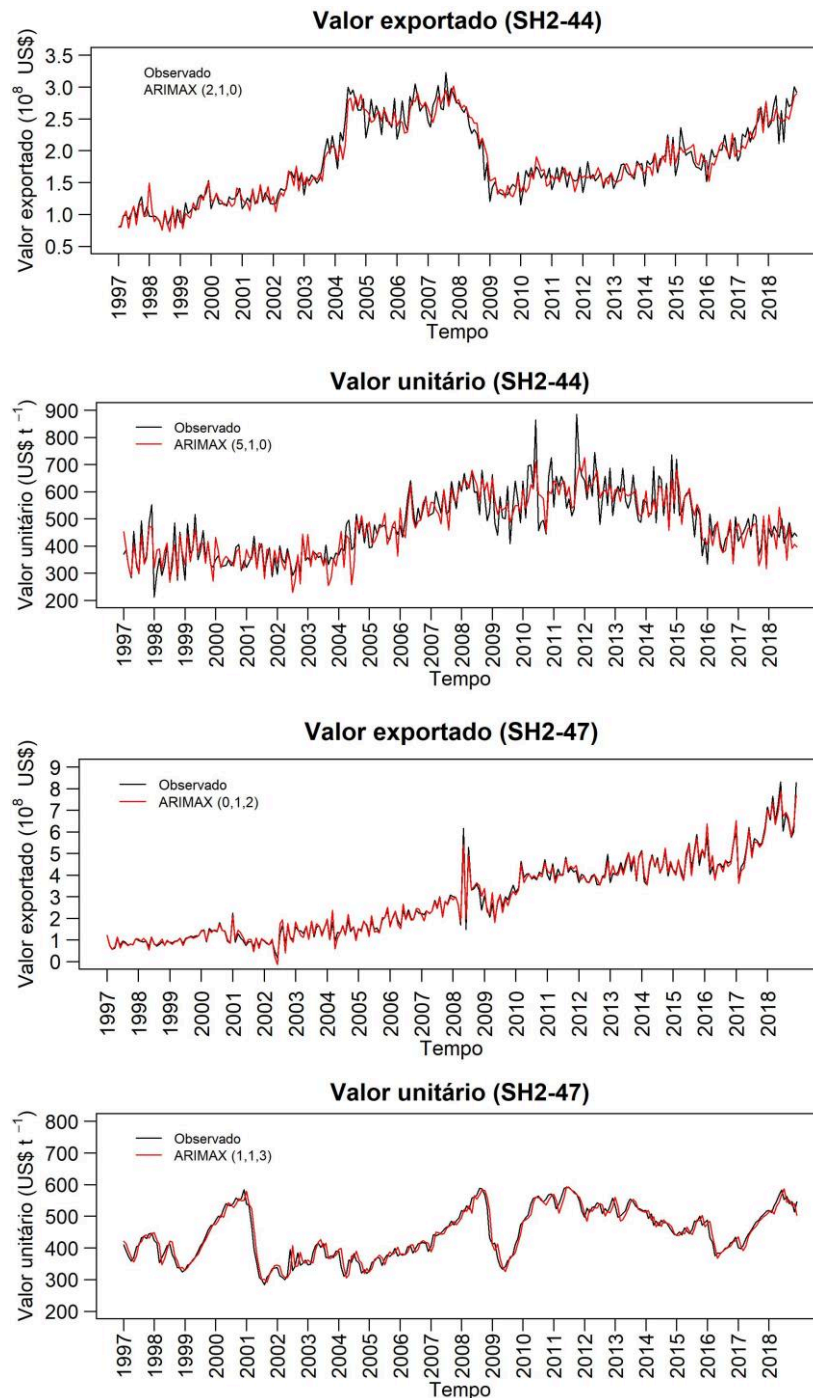


Figura 12 - Valores observados e preditos das variáveis séries temporais preditas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) utilizando os modelos ARIMAX para a abordagem 2.

O teste Ljung-Box para os resíduos dos modelos ARIMA e ARIMAX apresentaram  $p$ -valores maiores que 0,05, sendo assim, a hipótese de que os resíduos dos modelos não possuem autocorrelação e são ruídos brancos foi confirmada (Tabela 12).

Tabela 12 - Teste Ljung-Box dos resíduos dos modelos para a previsão das séries temporais dos grupos SH2-44 e SH2-47 por abordagem.

Abordagem	Variável	Grupo	Modelo	Q*	p-valor
Abordagem 1	Valor exportado	SH2-44	ARIMA (2,1,0)	5,54	0,7847
		SH2-47	ARIMA (1,1,1)	15,96	0,1008
	Valor unitário	SH2-44	ARIMA (1,1,3)	14,59	0,0677
		SH2-47	ARIMA (1,1,3)	6,60	0,4712
	Quantidade exportada	SH2-44	ARIMA (3,1,1)	7,27	0,5078
		SH2-47	ARIMA (1,1,1)	16,46	0,0580
Abordagem 2	Valor exportado	SH2-44	ARIMAX (2,1,0)	7,01	0,5352
		SH2-47	ARIMAX (0,1,2)	8,54	0,3830
	Valor unitário	SH2-44	ARIMAX (5,1,0)	5,13	0,0771
		SH2-47	ARIMAX (1,1,3)	4,75	0,4467

Em que: Q\* = valor calculado no teste de Ljung-Box ( $\alpha = 5\%$ ).

A dispersão dos resíduos em função do tempo, gráfico de autocorrelação e histograma dos resíduos dos modelos ARIMA e ARIMAX para os dois grupos de produtos estão apresentados nas Figura 13 e 14, respectivamente. As dispersões dos resíduos de todas as séries dos dois grupos apresentaram oscilação entre o eixo zero e variação relativamente constante. Os gráficos de ACF confirmaram a não autocorrelação dos resíduos, com os picos contidas em grande parte dentro dos limites das linhas tracejadas. A frequência dos resíduos de todas as séries temporais e grupos apresentaram uma distribuição aproximadamente normal.

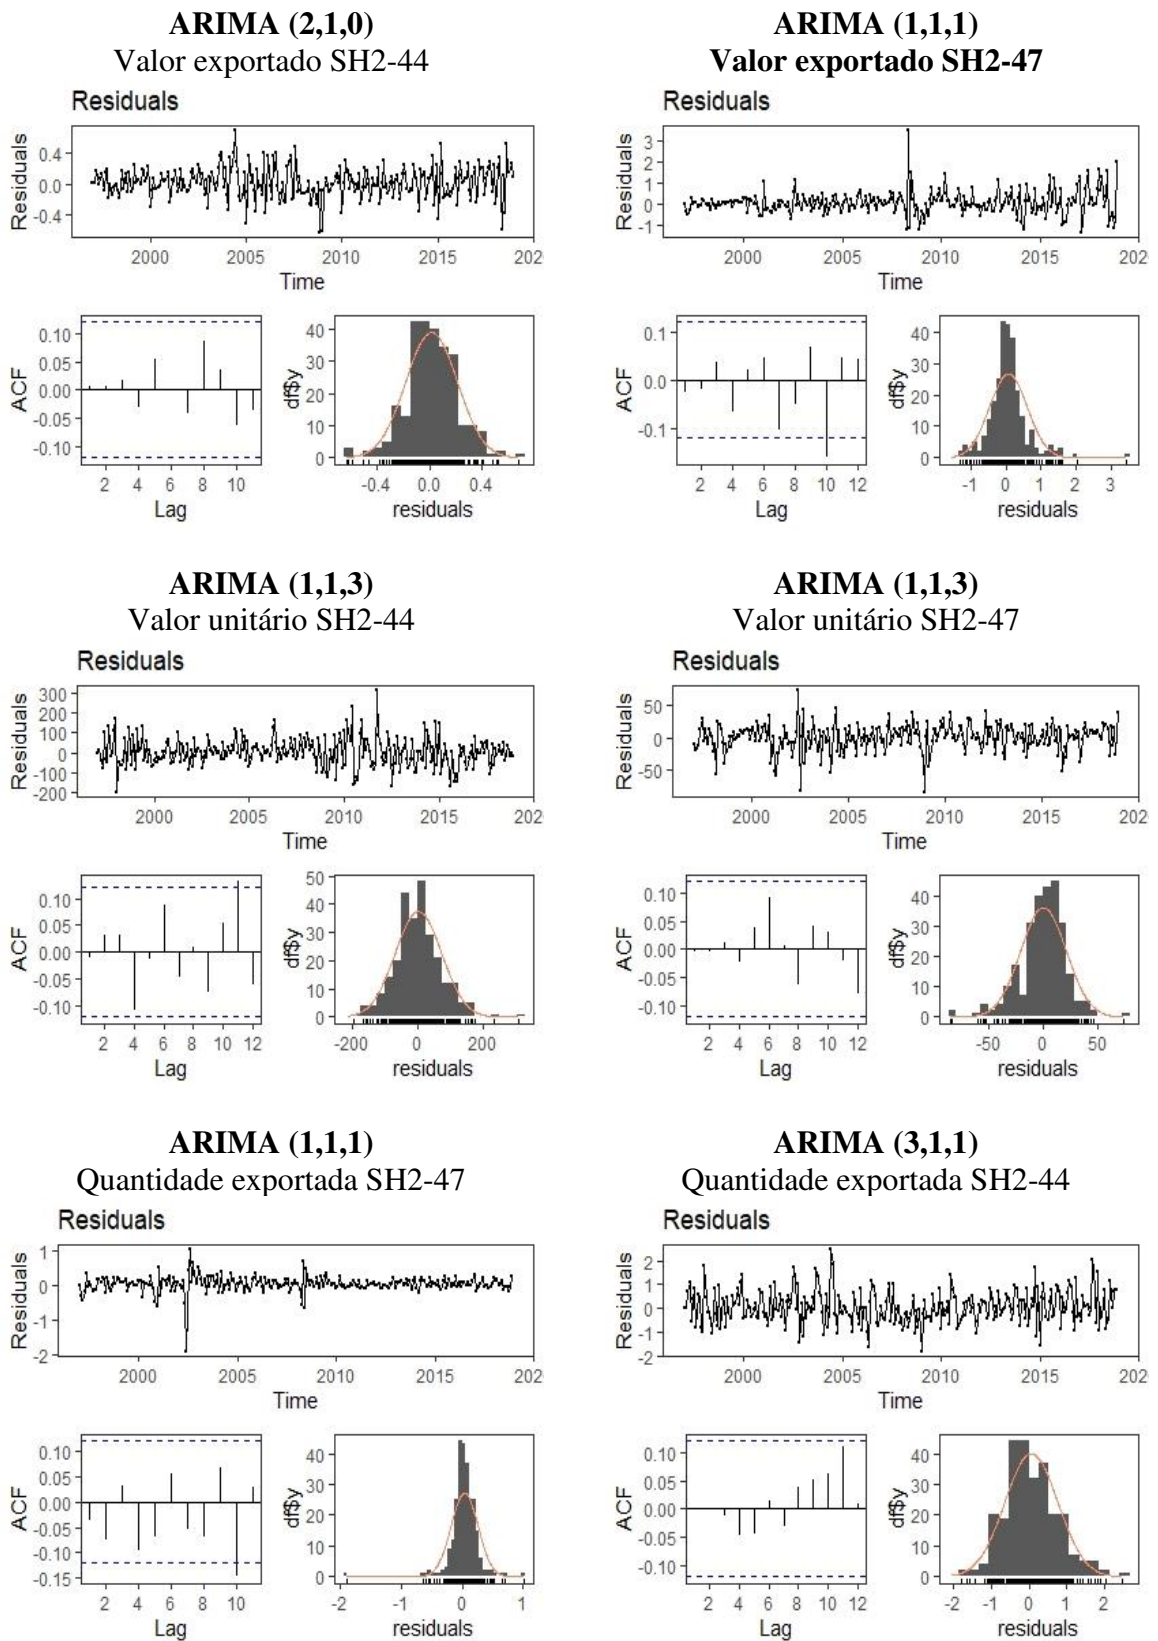


Figura 13 - Análise gráfica dos resíduos das séries temporais previstas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) utilizando os modelos ARIMA.

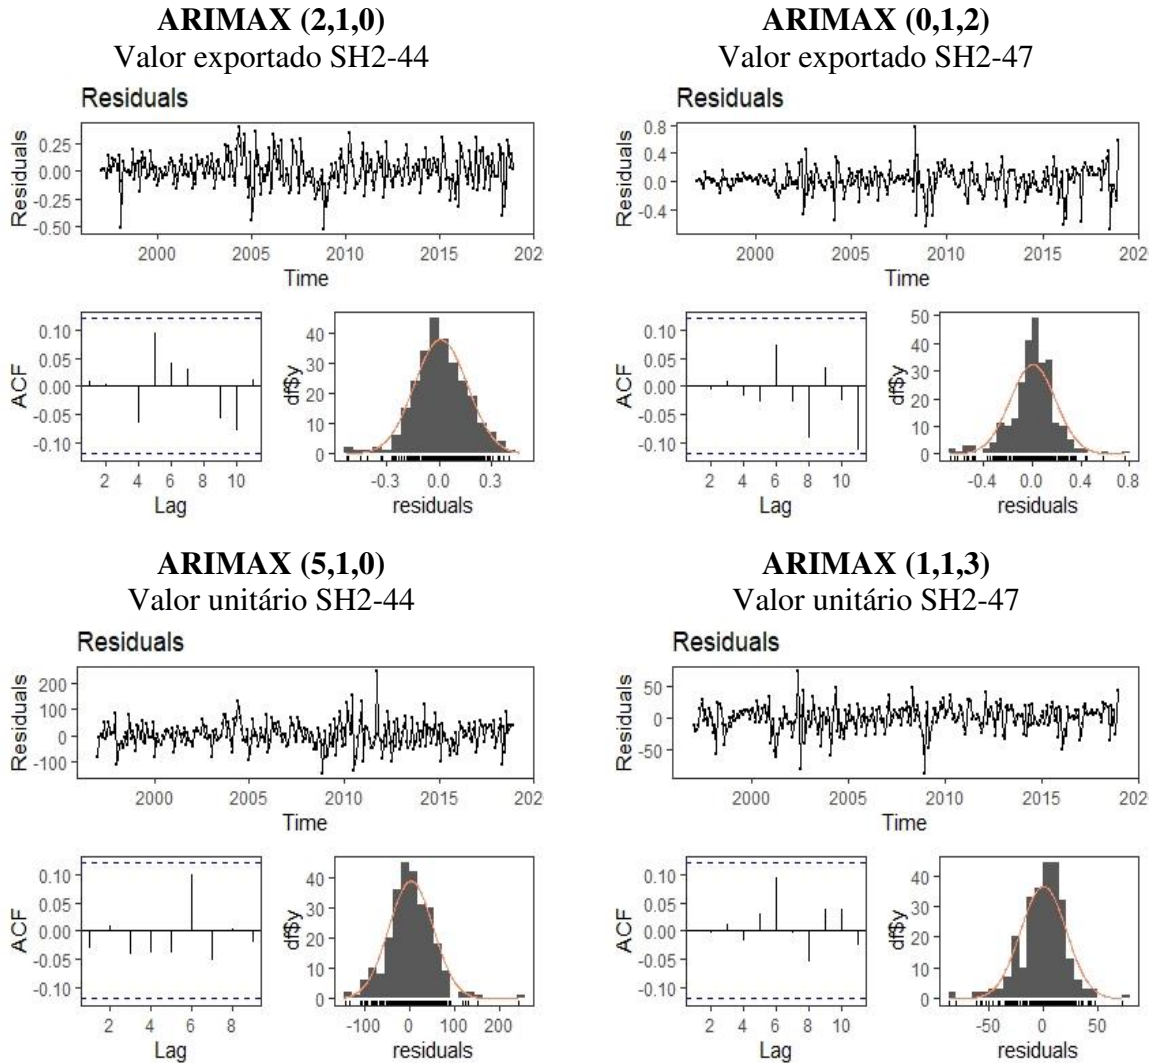


Figura 14 - Análise gráfica dos resíduos das séries temporais preditas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) utilizando os modelos ARIMAX.

Os gráficos ACF e PACF confirmaram a não correlação dos resíduos e que todos os modelos ARIMA e ARIMAX dos grupos SH2-44 e SH2-47 possuem ruídos brancos (Figuras 15, 16, 17 e 18). Dessa forma, os modelos selecionados foram utilizados nas etapas de previsão das séries temporais para o ano de 2019.

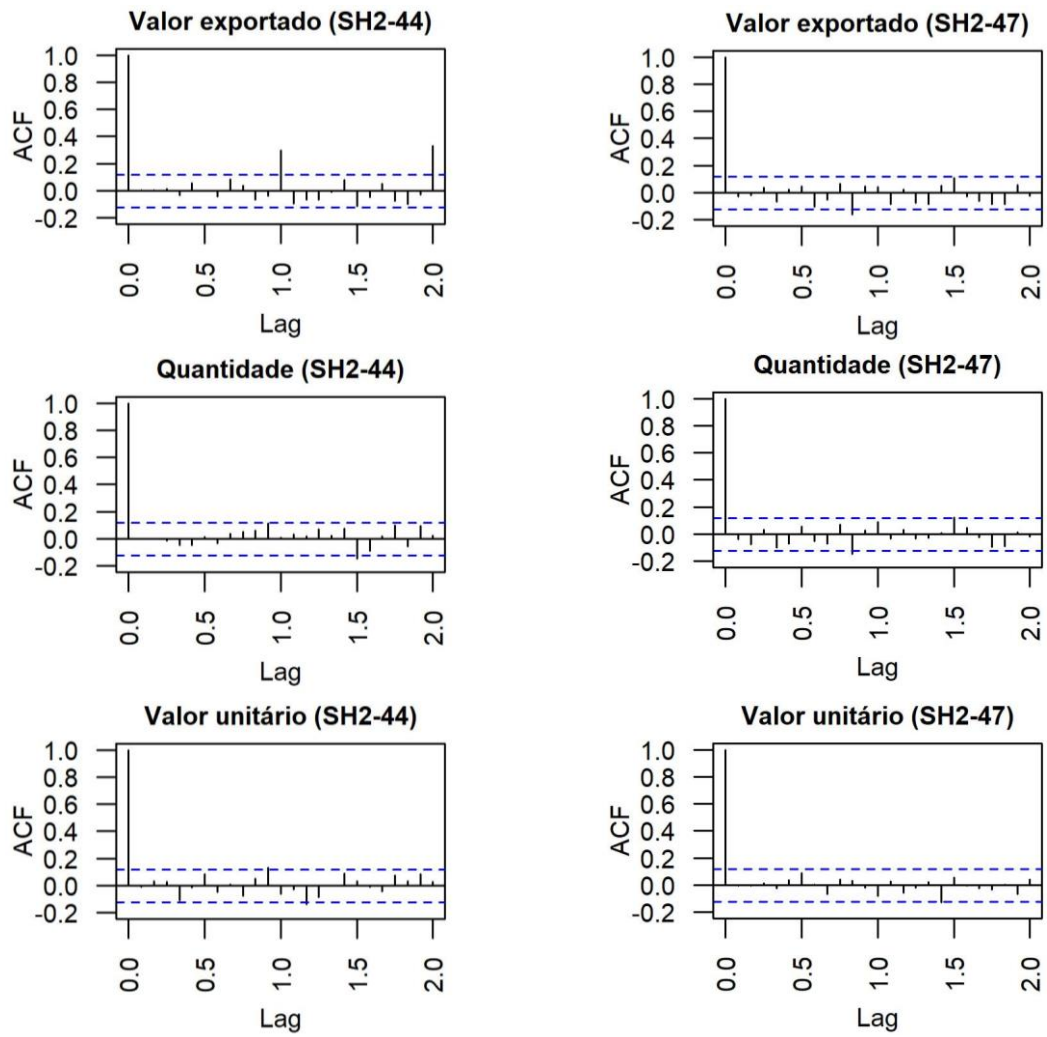


Figura 15 - Gráficos da autocorrelação (ACF) dos resíduos das séries temporais previstas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) utilizando o modelo ARIMA para a abordagem 1.

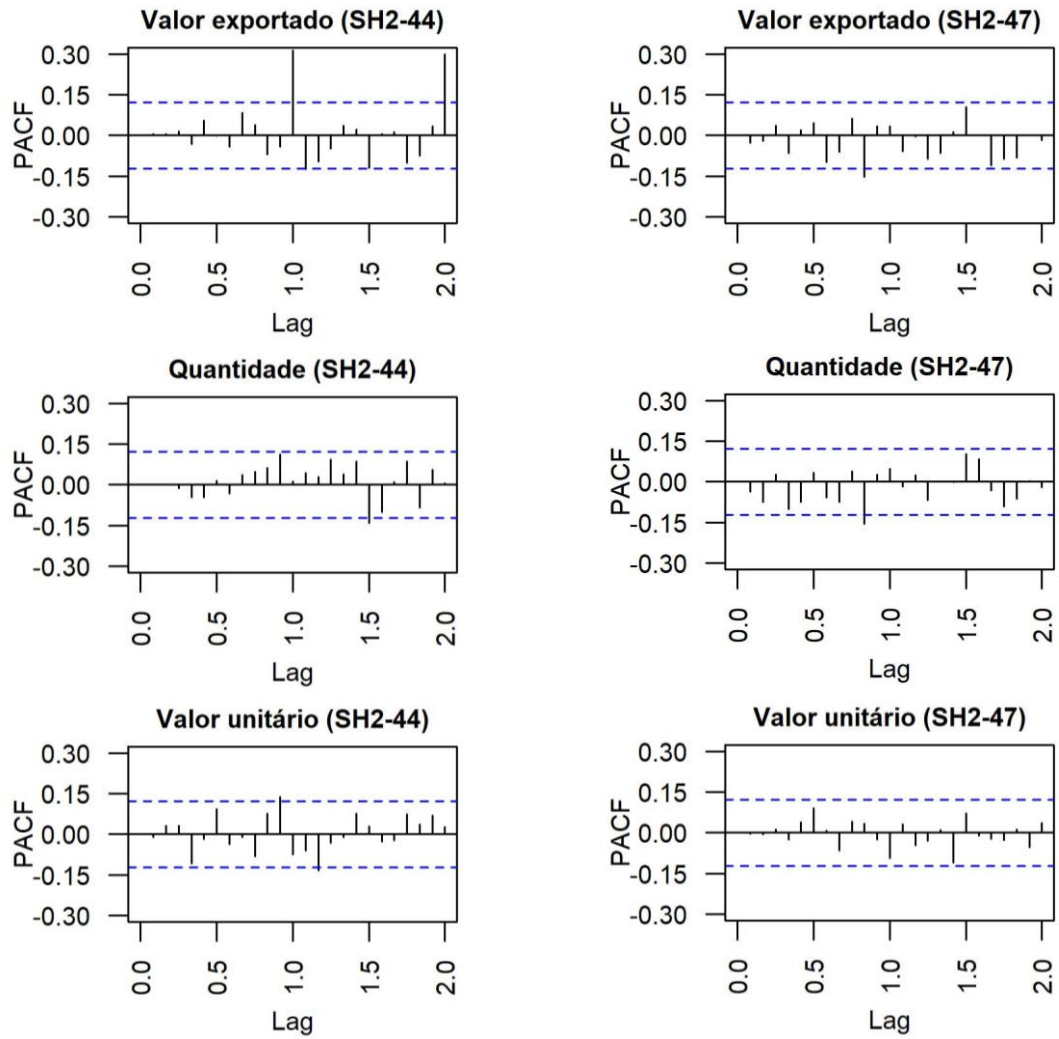


Figura 16 - Gráficos da autocorrelação parcial (PACF) dos resíduos das séries temporais preditas das variáveis valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) utilizando o modelo ARIMA para a abordagem 1.

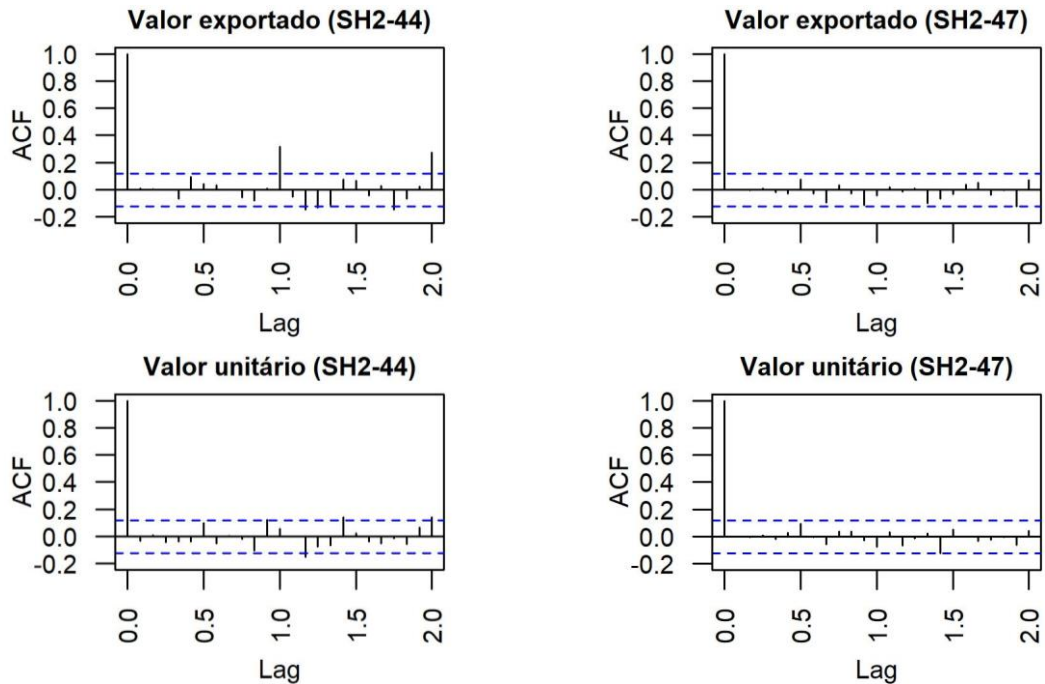


Figura 17 - Gráficos da autocorrelação (ACF) dos resíduos das séries temporais previstas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$  $t^{-1}$ ) utilizando o modelo ARIMAX para a abordagem 2.

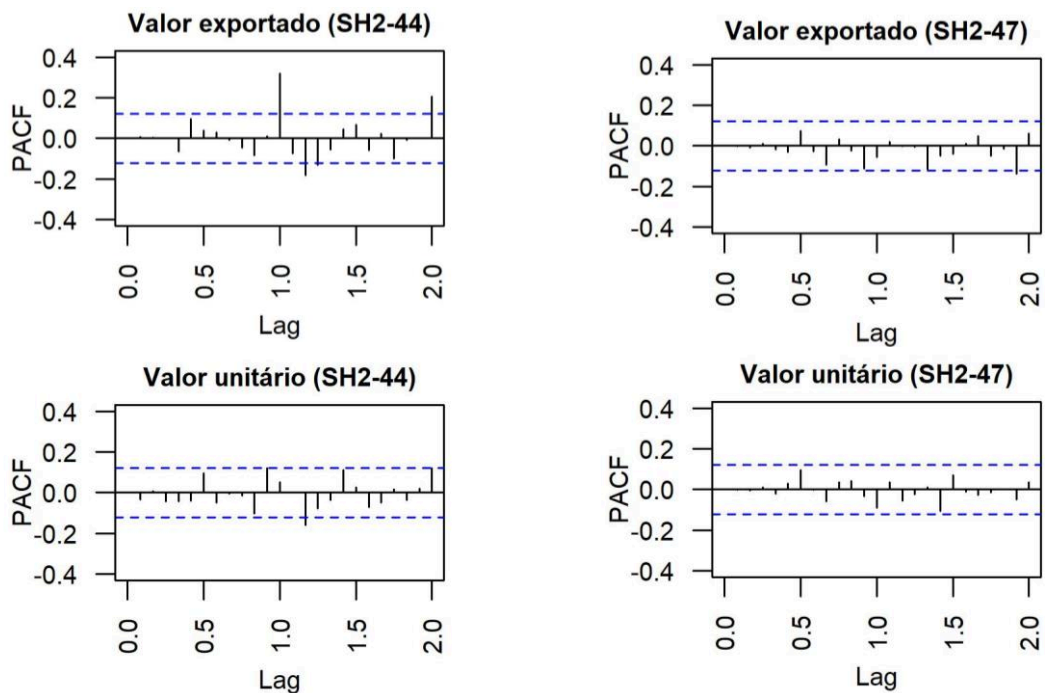


Figura 18 - Gráficos da autocorrelação parcial (PACF) dos resíduos das séries temporais previstas das variáveis valor exportado (US\$) e valor unitário de uma tonelada (US\$  $t^{-1}$ ) utilizando o modelo ARIMAX para a abordagem 2.

### 4.3 Modelagem com RNA

O algoritmo *Resilient Propagation* (Rprop) gerou 80% das RNA com maior acurácia para prever as séries temporais de forma individual e 100% das RNA para prever as séries temporais de forma generalizada para cada grupo de produtos dentro das abordagens. Já o algoritmo *Scaled Conjugate Gradient* (SCG) gerou apenas duas redes com maior precisão na validação, sendo elas RNA-I4 e RNA-I7 para prever as séries individuais do valor unitário e valor total exportado dos grupos SH2-44 e SH2-47 (Tabela 13).

As funções de ativação exponencial, tangente hiperbólica e logística corresponderam, respectivamente, em 65%, 30% e 5% das RNA selecionadas na validação. A função com maior frequência na abordagem 1 foi a exponencial para os dois grupos de produtos. Por outro lado, essa função na abordagem 2 obteve maior frequência apenas para o grupo SH2-44, enquanto para o grupo SH2-47 a tangente hiperbólica obteve maior frequência.

O número de neurônios da camada oculta das redes selecionadas na validação variou entre 16 e 30, sendo que as RNA que prevê as séries temporais de forma generalizada da abordagem 2 apresentaram os maiores números de neurônios (26-30), ao comparar com a abordagem 1 (20-21).

Após o treinamento, a RNA-G1 da abordagem 1 e a RNA-G3 da abordagem 2 aumentaram a acurácia dos resultados na validação de todas as séries previstas, com uma redução dos valores de *RMSE (%)* e *MAPE*.

Na abordagem 1, as RNA da série quantidade exportada nos dois grupos de produtos apresentaram estatísticas precisas na validação, com valores de *RMSE (%)* menores que 10% e *MAPE* menores que 12%. Por outro lado, o *RMSE (%)* e *MAPE* da validação da série valor total exportado nas duas abordagens foram maiores, com valores entre 10%–23% e 9,7%–18%, respectivamente. As RNA da série valor unitário de uma tonelada do grupo SH2-47 nas duas abordagens apresentaram estatísticas com menor precisão na validação, com *RMSE (%)* e *MAPE* variando entre 12%–22% e 14%–21%, respectivamente. Entretanto, a mesma série para o grupo SH2-44 foi mais precisa na validação, com *RMSE (%)* e *MAPE* variando entre 7%–13% e 5%–11%, respectivamente.


Tabela 13 - Estatísticas de precisão do treinamento e validação das Redes Neurais Artificiais selecionadas para previsão das séries temporais.

	Variável predita	Grupo	Rede	N° neurônios	Algoritmo	Função de ativação - CO	Treinamento		Validação	
							RMSE (%)	MAPE	RMSE (%)	MAPE
Abordagem 1	Valor exportado	SH2-44	RNA-G1	21	Rprop	Exponencial	12,48	9,48	10,70	9,72
			RNA-I1	16	Rprop	Tangente	12,20	10,08	14,10	13,00
		SH2-47	RNA-G2	20	Rprop	Exponencial	16,98	16,01	21,45	17,82
			RNA-I2	24	Rprop	Exponencial	17,34	14,71	18,70	14,62
	Valor unitário	SH2-44	RNA-G1	21	Rprop	Exponencial	13,01	9,28	12,68	11,08
			RNA-I3	19	Rprop	Exponencial	13,43	10,00	7,06	5,19
		SH2-47	RNA-G2	20	Rprop	Exponencial	9,80	7,21	21,75	20,94
			RNA-I4	29	SCG	Tangente	11,54	10,70	14,95	14,11
	Quantidade exportada	SH2-44	RNA-G1	21	Rprop	Exponencial	13,18	15,56	8,03	9,54
			RNA-I5	25	Rprop	Exponencial	13,88	16,60	9,69	11,11
		SH2-47	RNA-G2	20	Rprop	Exponencial	14,66	14,91	7,76	10,86
			RNA-I6	27	Rprop	Logística	6,77	8,94	8,19	11,90
Abordagem 2	Valor exportado	SH2-44	RNA-G3	26	Rprop	Exponencial	32,96	26,97	13,75	12,40
			RNA-I7	30	SCG	Tangente	27,58	21,35	13,67	11,70
		SH2-47	RNA-G4	30	Rprop	Tangente	15,93	15,71	18,56	17,49
			RNA-I8	18	Rprop	Tangente	14,63	13,33	22,09	20,75
	Valor unitário	SH2-44	RNA-G3	26	Rprop	Exponencial	20,67	12,82	7,31	5,85
			RNA-I9	17	Rprop	Exponencial	12,42	9,34	8,86	6,21
		SH2-47	RNA-G4	30	Rprop	Tangente	11,06	9,84	14,73	13,93
			RNA-I10	17	Rprop	Exponencial	14,61	12,12	12,72	12,03


O comportamento gráfico das séries temporais com os valores observados e previstos na validação das RNA para prever as séries temporais de forma individual e generalizada para cada grupo de produtos dentro da abordagem 1 estão na Figura 19. A maioria das RNA dessa abordagem não acompanharam o comportamento das séries temporais originais com suas oscilações ao longo dos meses do ano de 2018, sendo observado um comportamento com valores aproximadamente constantes ao longo do tempo, formando quase uma reta na previsão das séries (Figura 19).

As RNA da série quantidade exportada (RNA-G1, RNA-G2, RNA-I5 e RNA-I6) apresentaram a melhor dispersão dos valores previstos e maior acurácia ao comparar com as séries previstas dos dois grupos na abordagem 1. Na validação, a RNA-G2 e RNA-I4 apresentaram uma subestimação das séries previstas do valor unitário do grupo SH2-47. As RNA do grupo SH2-44 obtiveram melhor comportamento gráfico pela RNA-I3. As RNA-G1 e RNA-I1 na validação das séries do valor exportado para o grupo SH2-44 geraram valores próximos aos observados. No grupo SH2-47, as RNA-G2 e RNA-I2 subestimaram levemente os valores observados.


RNA-G1




RNA-I1




RNA-G2




RNA-I2




RNA-G1




RNA-I3



RNA-G2



RNA-I4



RNA-G1



RNA-I5



RNA-G2



RNA-I6




Figura 19 - Gráficos da validação das Redes Neurais Artificiais para previsão séries temporais do valor exportado (US\$), quantidade exportada (t) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) para os grupos SH2-44 e SH2-47 na abordagem 1.

O comportamento das séries temporais com os valores observados e previstos na validação das RNA para prever as séries temporais de forma individual e generalizada para cada grupo de produtos dentro da abordagem 2 estão na Figura 20. A maioria das RNA dessa

abordagem capturaram melhor o comportamento e as oscilações das séries temporais originais (Figura 20). As séries do valor exportado previstas pelas RNA-G4 e RNA-I8 geraram curvas com comportamentos coincidentes e uma subestimação dos valores do grupo SH2-47. Já a RNA-G3 e RNA-I7 da mesma variável para o grupo SH2-44 obteve resultados próximos aos observados.

As RNA que previram o valor unitário para o grupo SH2-47 na abordagem 2 subestimaram os valores observados. A RNA-G3 foi a melhor na validação na série do valor unitário para o grupo SH2-44. As séries da RNA individual e geral do valor exportado da abordagem 2 foram parecidas graficamente com comportamento similares em cada grupo de produtos.


RNA-G3




RNA-I7




RNA-G4




RNA-I8




RNA-G3



RNA-I9



RNA-G4



RNA-I10




Figura 20 - Gráficos da validação das Redes Neurais Artificiais para previsão séries temporais do valor exportado (US\$) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) para os grupos SH2-44 e SH2-47 na abordagem 2.

#### 4.4 Previsão das séries temporais com os modelos ARIMA, ARIMAX e RNA

As estatísticas da previsão das séries temporais dos modelos ARIMA na abordagem 1 e ARIMAX na abordagem 2 apresentaram menor precisão ao comparar com as RNA, com *RMSE* (%) entre 10%–29% e *MAPE* entre 8%–27% para os modelos ARIMA e *RMSE* (%) e *MAPE* entre 15%–28% e 16%–29% para os modelos ARIMAX (Tabela 14).

Tabela 14 - Estatísticas de precisão da previsão das séries temporais com as Redes Neurais Artificiais e os modelos ARIMA e ARIMAX para os meses do ano de 2019.

Abordagem	Variável predita	Grupo	Modelo/RNA	<i>RMSE</i> (%)	<i>MAPE</i>
Abordagem 1	Valor exportado	SH2-44	ARIMA (2,1,0)	21,74	21,17
			RNA-G1	10,29	8,83
			RNA-I1	8,99	7,42
		SH2-47	ARIMA (1,1,1)	28,26	24,99
			RNA-G2	24,62	16,25
			RNA-I2	25,75	19,78
	Valor unitário	SH2-44	ARIMA (1,1,3)	13,69	12,52
			RNA-G1	12,69	9,17
			RNA-I3	9,67	8,04
		SH2-47	ARIMA (1,1,3)	28,62	27,45
			RNA-G2	20,62	16,23
			RNA-I4	14,95	14,11
	Quantidade exportada	SH2-44	ARIMA (3,1,1)	10,22	8,52
			RNA-G1	10,11	8,38
RNA-I5			8,14	7,61	
SH2-47		ARIMA (1,1,1)	14,49	8,82	
		RNA-G2	13,33	8,55	
		RNA-I6	11,90	8,19	
Abordagem 2	Valor exportado	SH2-44	ARIMAX (2,1,0)	17,43	16,45
			RNA-G3	8,84	5,99
			RNA-I7	4,63	3,88
		SH2-47	ARIMAX (0,1,2)	22,15	19,37
			RNA-G4	22,47	18,40
	Valor unitário	SH2-44	RNA-I8	26,47	19,00
			ARIMAX (5,1,0)	16,59	15,47
			RNA-G3	13,71	12,06
		SH2-47	RNA-I9	9,53	8,28
			ARIMAX (1,1,3)	29,18	28,01
		SH2-47	RNA-G4	14,73	13,93
			RNA-I10	12,72	12,03

As previsões das séries temporais com as RNA de forma individual foram mais precisas do que com as RNA de forma generalizada para cada grupo de produtos dentro das abordagens. A exceção foi a série valor exportado do grupo SH2-47, em que as RNA gerais (RNA-G2 e

RNA-G4) obtiveram maior acurácia na previsão ao comparar com as RNA individuais (RNA-I2 e RNA-I8) nas abordagens avaliadas.


As previsões com maior acurácia das séries valor exportado, quantidade exportada e valor unitário de uma tonelada para o grupo SH2-44 foram com a RNA-I7, RNA-I5 e RNA-I9, respectivamente. No grupo SH2-47, a RNA-G4, RNA-I6 e RNA-I10 foram as de maior acurácia, respectivamente. A maior parte das RNA gerais não foram as mais acuradas na previsão de todas as séries, contudo, os valores de *RMSE (%)* e *MAPE* foram menores que a maioria dos modelos ARIMA e ARIMAX, e próximos da maioria das RNA individuais.

O gráfico da previsão com o modelo ARIMA apresentou comportamento com tendência linear e constante ao longo do tempo, além disso não acompanham as oscilações e amplitudes dos dados originais das séries da abordagem 1 (Figura 21). As RNA individual e geral da abordagem 1 conseguiram captar apenas algumas oscilações, com menores amplitudes dos dados observados. Quanto maior a oscilação e amplitude das séries originais, menor foi a precisão das previsões com as RNA, como pode ser observado nas variáveis valor exportado do grupo SH2-47 e na série da variável valor unitário dos grupos SH2-44 e SH2-47 na abordagem 1.

ARIMA (2,1,0)




ARIMA (1,1,1)



RNA-G1



RNA-G2



RNA-I1



RNA-I2



ARIMA (1,1,3)

ARIMA (1,1,3)

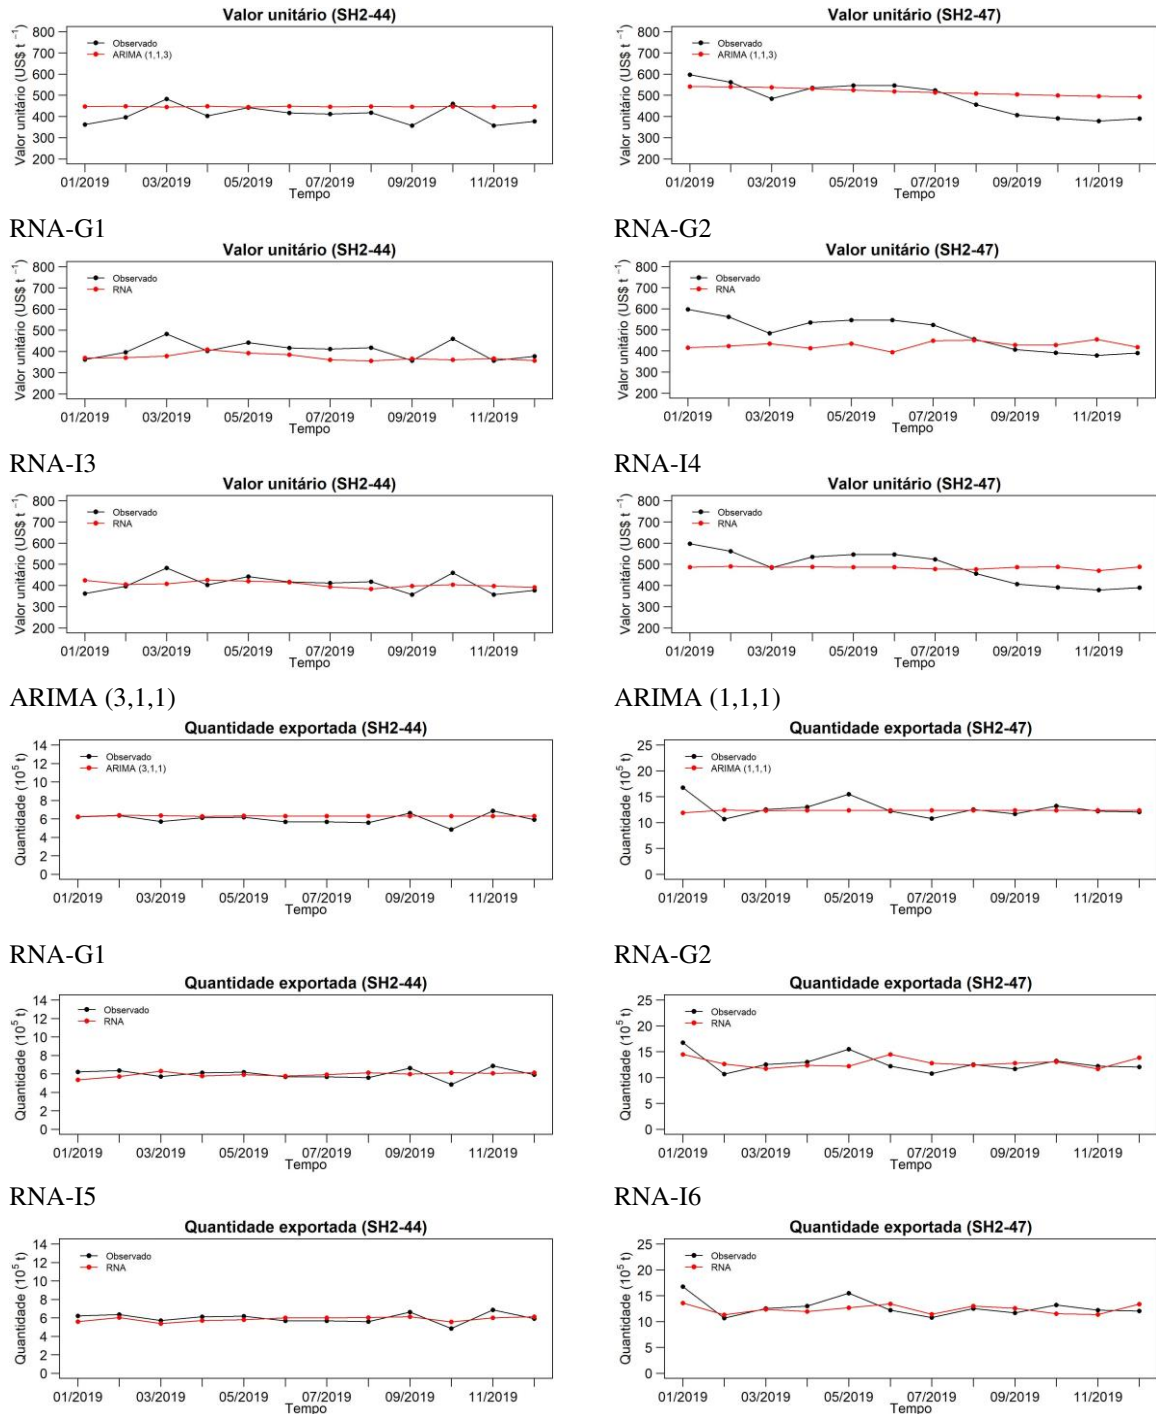


Figura 21 - Gráficos dos valores previstos e observados das séries temporais do valor exportado (US\$) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) pelo modelo ARIMA e Redes Neurais Artificiais para os grupos SH2-44 e SH2-47 na abordagem 1.

Os modelos ARIMAX e as RNA individuais e geral da abordagem 2 conseguiram captar o comportamento e as oscilações das séries temporais originais das variáveis valor exportado e valor unitário dos grupos SH2-44 e valor exportado do grupo SH2-47 (Figura 22). As previsões da série valor unitário para o grupo SH2-47 com o modelo ARIMAX na abordagem 2 apresentaram valores aproximadamente constantes e sem oscilações. Já as RNA individual e

geral não acompanharam a oscilação e a tendência de decréscimo dos dados observados da série original.

ARIMAX (2,1,0)




ARIMAX (0,1,2)



RNA-G3




RNA-G4




RNA-I7




RNA-I8




ARIMAX (5,1,0)




ARIMAX (1,1,3)




RNA-G3



RNA-G4



RNA-I9



RNA-I10




Figura 22 - Gráficos dos valores previstos e observados das séries temporais do valor exportado (US\$) e valor unitário de uma tonelada (US\$ t<sup>-1</sup>) pelo modelo ARIMAX e Redes Neurais Artificiais para os grupos SH2-44 e SH2-47 na abordagem 2.

#### **4.5 Matriz SWOT da técnica RNA e modelos ARIMA e ARIMAX**

A Matrizes SWOT com as forças (*strengths*), fraquezas (*weaknesses*), oportunidades (*opportunities*) e ameaças (*threats*) da utilização dos modelos ARIMA e ARIMAX e da técnica Redes Neurais Artificiais para previsão de séries temporais estão apresentados nas Tabelas 15 e 16.

Tabela 15 - Matriz SWOT da aplicação dos modelos ARIMA/ARIMAX na previsão de séries temporais

FORÇAS ( <i>STRENGTHS</i> )	FRAQUEZAS ( <i>WEAKNESSES</i> )
<ul style="list-style-type: none"> <li>• Modelo ARIMA é um dos mais difundidos para análise de previsão de séries temporais;</li> <li>• Com o modelo ARIMAX é possível incorporar uma ou mais séries temporais em um modelo para prever outra série;</li> <li>• Método robusto;</li> <li>• Facilidade para ajuste.</li> </ul>	<ul style="list-style-type: none"> <li>• Esses modelos assumem uma relação linear entre a variável dependente e independente;</li> <li>• Não podem prever várias séries ao mesmo tempo;</li> <li>• O modelo ARIMA pode não captar com eficácia padrões não lineares ocultos em uma série temporal;</li> <li>• Requer um grande número de observações;</li> <li>• Testes para adequação dos dados e uso dos modelos são necessários;</li> <li>• Geram um grande volume de dados para análise;</li> <li>• É necessário atender alguns pressupostos: ter estacionaridade, não ter autocorrelação, ruídos brancos;</li> <li>• É indicado utilizar o ARIMA para previsões de curto prazo;</li> <li>• O processo de escolha do melhor modelo pode ter certa subjetividade.</li> </ul>
OPORTUNIDADES ( <i>OPPORTUNITIES</i> )	AMEAÇAS ( <i>THREATS</i> )
<ul style="list-style-type: none"> <li>• Criação de modelos híbridos que englobem padrões lineares e não lineares.</li> <li>• O uso de modelos híbridos, ARIMA-ANN proporciona ótimos resultados de predição, permitindo tomadas de decisão para prosseguir com um planejamento mais racional da produção e do mercado de madeira.</li> </ul>	<ul style="list-style-type: none"> <li>• Surgimento de novas técnicas de previsão com maior acurácia;</li> <li>• Novos modelos que geram um volume menor de dados, que não necessitam tantos passos para uso e possuem flexibilidade na análise de dados.</li> </ul>

Tabela 16 - Matriz SWOT da aplicação da Redes Neurais Artificiais na previsão de séries temporais.

FORÇAS ( <i>STRENGTHS</i> )	FRAQUEZAS ( <i>WEAKNESSES</i> )
<ul style="list-style-type: none"> <li>• Descreve os comportamentos lineares e não-lineares das séries temporais.</li> <li>• As RNA são orientadas por dados sem distribuição; portanto, eles podem aproximar funções não lineares e resolver os problemas em que a relação entrada-saída não é facilmente computável;</li> <li>• Tolerância a ruídos;</li> <li>• Boa capacidade de generalização dos dados;</li> <li>• Conseguir prever mais de uma série temporal com apenas uma RNA;</li> <li>• É possível adicionar inúmeras variáveis exógenas explicativas na modelagem.</li> <li>• Capacidade de modelar as séries não estacionárias com tendências, sazonalidades, correlação e ciclos sem transformação prévia dos dados.</li> </ul>	<ul style="list-style-type: none"> <li>• Pode ocorrer memorização dos padrões de treinamento com um super ajustamento dos dados;</li> <li>• Treinamento demorado: dependendo da aplicação da rede neural, o treinamento pode ser demorado, demorando horas ou mesmo dia;</li> <li>• Ter um conhecimento técnico da aplicação das redes para conseguir aplicar;</li> <li>• Dificuldade na interpretação dos parâmetros de uma RNA;</li> <li>• Pode exigir um esforço computacional grande;</li> <li>• Perda de dados na etapa de treinamento com a retirada dos dados de validação.</li> <li>• Definir a melhor configurações/topologias adequada para um determinado problema.</li> </ul>
OPORTUNIDADES ( <i>OPPORTUNITIES</i> )	AMEAÇAS ( <i>THREATS</i> )
<ul style="list-style-type: none"> <li>• Automatização de conhecimentos empíricos a partir de uma base de exemplos de aprendizado referente a um problema;</li> <li>• O uso de Redes Neurais Artificiais torna-se cada vez mais uma opção atrativa, haja vista a atual ampliação da capacidade computacional;</li> <li>• O uso de modelos híbridos, ARIMA-ANN proporciona ótimos resultados de predição, permitindo tomadas de decisão para prosseguir com um planejamento mais racional da produção e do mercado de madeira;</li> <li>• Existem várias opções de configurações e topologias a serem testadas.</li> </ul>	<ul style="list-style-type: none"> <li>• Outras técnicas com menos hiperparâmetros a serem configurados e com boa performance.</li> </ul>

## 5 DISCUSSÃO

Técnicas para previsão de variáveis associadas à exportação são ferramentas importantes para subsidiar o planejamento e tomada de decisões do governo e de gestores de empresas de um país (DAVE et al., 2021; QONITA; PERTIWI; WIDIYANINGTYAS, 2017). No presente estudo duas técnicas utilizadas para previsão de séries temporais da exportação dos principais produtos florestais madeireiros do Brasil foram avaliadas e comparadas, sendo elas a metodologia Box-Jenkins com os modelos ARIMA e ARIMAX e as Redes Neurais Artificiais (RNA). As RNA demonstraram melhor performance das métricas estatísticas para previsão das séries temporais em comparação aos modelos ARIMA e ARIMAX.

A tendência de aumento das séries valor exportado e quantidade exportada do grupo SH2-47, o qual é representado, principalmente, pela celulose pode ser explicado por diversos fatores. Entre eles, cita-se o aumento da demanda externa, principalmente China, Estados Unidos e Europa; competência da indústria brasileira em ofertar a celulose para o mercado; potencial de produção de florestas de eucalipto no Brasil; investimentos em ampliação e capacitação das indústrias instaladas; investimentos em tecnologias utilizadas nas plantações; e adequação dos produtos à níveis exigidos internacionalmente (COELHO JUNIOR et al., 2018; INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATISTICA, 2020).

A maior amplitude e crescimento das séries do valor exportado (16,1 milhões a 1 bilhão US\$) e quantidade (40,90 mil a 1,67 milhão de toneladas) de celulose indica que o mercado de exportação de celulose para o setor florestal é promissor, sendo que a tendência é que o mercado seja próspero e crescente. As linhas suaves e menor oscilação mensal da série valor unitário de uma tonelada do grupo de produtos SH2-47 indica que o comércio desses produtos não se abala de forma drástica e tende a aumentar ao longo dos anos, realçando a sua importância na economia do Brasil.

A maiores oscilações (desvio padrão) mensal ao longo do tempo das séries do grupo SH2-47 ocorreu devido ao ataque terrorista aos Estados Unidos em setembro 2001 refletiu uma queda nas exportações em 2002 (COELHO JUNIOR et al., 2018). Em 2008 houve uma grande oscilação com o impacto da crise econômica mundial (Crise imobiliária nos Estados Unidos) (ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS, 2009).

As séries valor exportado e quantidade exportada do grupo SH2-44 apresentaram um leve crescimento, o qual é representado principalmente pelos produtos derivados de madeira (madeira serrada, compensados, etc.). Tal acontecimento pode ter ocorrido devido a expansão

do mercado global, mais especificamente dos Estados Unidos, o qual é um dos grandes importadores desses produtos (INDÚSTRIA BRASILEIRA DE ÁRVORES, 2020).

As exportações dos produtos florestais madeireiros do grupo SH2-44 cresceram até 2007. Entretanto, a partir desse período, esse crescimento apresentou menor taxa, reduzindo com uma redução nos anos de 2008 e 2009. Esse fato ocorreu em função da crise econômica global, a qual afetou a economia mundial e, conseqüentemente, o setor florestal do Brasil, o qual é sensível às políticas públicas relacionadas com a legislação, tributação, taxa de câmbio e taxa de juros (FERREIRA NETO, 2005; ROSADO et al., 2006; SOARES et al., 2010a). Desde então, a exportação de produtos florestais madeireiros do grupo SH2-44 se recuperou de forma contínua e gradual e obteve crescimento mais acentuado após o ano de 2015, devido ao reaquecimento econômico que continuou nos próximos anos em função ao desenvolvimento econômico global (FAO, 2014, 2016, 2018).

As exportações dos grupos de produtos madeireiros brasileiros SH2-44 e SH2-47, representados principalmente pela madeira serrada e celulose, respectivamente, tendem a aumentar ao longo dos anos, apesar das crises econômicas mundiais ao longo dos anos. Este fato mostra a importância das exportações de produtos florestais na economia nacional.

Com relação à predição, o melhor desempenho das métricas estatísticas da predição das séries (1997 a 2018) com os modelos ARIMAX em comparação aos modelos ARIMA pode ser explicado pela presença da variável exógena quantidade exportada (BANAS; UTNIK-BANAS, 2021). Essa variável foi utilizada como variável de entrada na modelagem, demonstrando que variáveis explicativas podem melhorar a predição com os modelos.

O bom comportamento gráfico da predição das séries das variáveis com os modelos ARIMA e ARIMAX, principalmente na captação da tendência das séries, pode ser explicado por esses modelos utilizarem as observações passadas das próprias séries para prever os dados futuros (BOX et al., 2015). Os modelos ARIMAX captaram melhor as oscilações e amplitudes das séries temporais originais devido a variável quantidade exportada na modelagem, a qual influenciou o comportamento das séries temporais ajustadas.

O bom desempenho do algoritmo Rprop para gerar as RNA com maior precisão das estatísticas se deve a sua capacidade de treinar individualmente cada valor de matriz de peso individual, em que apenas o sinal do gradiente e a magnitude da descida é utilizado para atualizar os pesos (HEATON, 2011). O algoritmo Rprop não mantém um valor de atualização global, sendo que esses valores para atualização dos pesos mudam à medida que o treinamento avança (HAYKIN; HAYKIN, 2009; HEATON, 2011). Com isso, a complexidade do processamento aumenta e a taxa de erro reduz, gerando RNA mais eficientes.

O menor número de RNA com estatísticas mais precisas utilizando o algoritmo *Scaled Conjugate Gradient* (SCG) é devido ao processo de otimização para a redução da taxa de erros. O SCG usa um mecanismo de dimensionamento de tamanho de etapa. Isso significa que ele não faz uma pesquisa de linha em cada iteração de aprendizado, o que acelera a taxa de convergência, porém com menor precisão das estimativas. Ao invés de utilizar a busca em linha, o algoritmo SCG utiliza uma aproximação do cálculo da matriz hessiana (HAYKIN; HAYKIN, 2009; MEILLER, 1993; SELVAMUTHU; KUMAR; MISHRA, 2019).

A boa performance da função de ativação exponencial indica que ela é adequada à distribuição dos valores de entrada das séries temporais para as unidades de saída. Essa boa adequação pode ser devido a maioria dos valores de entrada serem positivos com tendência de crescimento, mas sem limite superior conhecido (KARLIK; OLGAC, 2011). Além disso, a função de ativação exponencial na camada oculta interfere na complexidade da aprendizagem e no desempenho da RNA devido sua capacidade de introduzir a não linearidade nas RNA, o que torna essas RNA multicamadas tão eficazes na representação de fenômenos não-lineares em casos de previsão de séries temporais (LECUN; BENGIO; HINTON, 2015; MOHAMMED; NAJI; ABDULJABBAR, 2019).

O bom desempenho das RNA com o maior número de neurônios na camada oculta indica que as RNA de estruturas complexas são necessárias para a previsão de séries temporais. Isso pode ser explicado pelo fato do número de neurônios na camada oculta ser responsável pela extração de características intrínsecas dos dados e de captar as relações entre as variáveis devido a presença das funções de ativação em cada neurônio (ZHANG, 2003; ZHANG; PATUWO; HU, 2001). O maior número de neurônios na camada oculta das RNA geral da abordagem 2 em comparação com a abordagem 1, está relacionado com a complexidade do problema apresentado às RNA. Isso foi devido a adição da série quantidade exportada na camada de entrada, sendo que quanto maior a quantidade de informação apresentada para a rede, maior será a quantidade de neurônios necessários para resolver o problema (BINOTI; BINOTI; LEITE, 2014).

Com relação à previsão, o desempenho inferior das métricas estatísticas das previsões com os modelos ARIMA e ARIMAX ao comparar com as RNA pode ser devido esses modelos captarem, na maioria dos casos, somente as relações lineares entre as variáveis dependentes e independentes nas séries temporais na modelagem (WUNSCH; LIESCH; BRODA, 2018; ZHANG, 2003).

A melhor performance das RNA treinadas para prever as séries individuais, em comparação com as RNA treinadas para prever as séries de forma geral está relacionada a menor

complexidade na estrutura de suas redes (BRAGA et al., 2021). Na modelagem das RNA para previsão de forma geral, é realizada a previsão de três séries temporais de maneira simultânea. Assim, a complexidade dessas redes aumenta devido a combinação dos pesos ajustados, número de neurônios da camada oculta, função de ativação e algoritmos para gerar apenas uma equação para prever todas as séries temporais com características distintas de cada grupo (GORGENS et al., 2014). Dessa forma, considerando a quantidade de restrições e dados inseridos, pode ser a explicação da redução na acurácia da previsão das séries. Contudo, as RNA gerais obtiveram um bom desempenho, com estatísticas precisas em todas as redes avaliadas. Isso demonstra a capacidade das redes em modelar séries temporais de forma mais complexa.

O comportamento com tendência linear das previsões com os modelos ARIMA na abordagem 1 indica que o modelo não conseguiu captar as relações não lineares das séries temporais originais. Já as RNA na mesma abordagem conseguiram captar algumas oscilações devido à sua capacidade de captar as relações não lineares intrínsecas nas séries (HAYKIN; HAYKIN, 2009). Porém, a menor captação das oscilações e amplitudes das séries pelas RNA para essa abordagem pode estar relacionado as topologias de rede testadas, sendo possivelmente necessário testar outras funções de ativação (que conseguem captar a não linearidade das séries) e mais camadas ocultas para captar melhor as oscilações e amplitudes dos dados originais para esse tipo de problema.

A captação do comportamento e oscilações das séries temporais originais pela maioria dos modelos ARIMAX e das RNA individuais e gerais da abordagem 2, confirma que ao adicionar uma variável independente explicativa na modelagem o desempenho das previsões melhora (CARTA et al., 2019). Além disso, a variável quantidade exportada influenciou diretamente na capacidade do modelo ARIMAX e das RNA em captar melhor o comportamento (amplitude, oscilações e tendências) das séries originais.

Com relação à matriz SWOT das RNA e dos modelos ARIMA e ARIMAX é possível detectar o desempenho de cada técnica para previsão de séries temporais. Os modelos tradicionais (ARIMA e ARIMAX) são robustos e têm facilidade no ajuste dos parâmetros, o que facilita o processamento dos dados (AHMED et al., 2017). Apesar desses modelos assumirem uma relação linear na série temporal, o que muitas vezes não acontece, é possível obter resultados com alta precisão (ZHANG, 2003).

Uma das principais desvantagens desses tipos de modelos é que as séries precisam atender a alguns pressupostos na pré-análise, como possuir estacionaridade e não existir autocorrelação na série, necessitando de maior quantidade de testes e volume de dados para análise antes e durante o processamento (KOUTROUMANIDIS; IOANNOU; ARABATZIS,

2009). Além disso, um número mínimo de observações para o processamento é necessário, o qual não deve ser inferior a 50 observações. Ainda, as previsões devem ser realizadas a curto prazo para obter maior precisão das estatísticas (BOX et al., 2015).

Em relação à técnica de RNA, essa tem se mostrado eficiente na previsão de séries temporais, gerando resultados com métricas estatísticas iguais ou melhores as técnicas tradicionais. Essa melhora é devido a sua estrutura complexa (camadas, número de neurônios, função de ativação e algoritmos), o que permite generalizar os dados, ter tolerância aos ruídos, identificar as relações entre as variáveis e ajustar os pesos de forma a reduzir os erros (TAVARES JÚNIOR et al., 2020). Algumas vantagens que se destacam nas RNA para essa aplicação são a possibilidade de prever várias séries com apenas uma RNA e a sua capacidade de captar e modelar os comportamentos lineares e não lineares presentes nas variáveis ao longo do tempo (HAYKIN; HAYKIN, 2009). Além disso, não é necessária a transformação prévia dos dados para tornar as séries estacionárias, sem tendências, retirar as sazonalidades, ciclos e autocorrelações entre os dados. Isso é interessante pois reduz o tempo e volume de dados de análise prévia ao comparar com as técnicas tradicionais.

Em relação às desvantagens das RNA, a memorização dos padrões de treinamento pode ocorrer e, como consequência, a rede não é capaz de se adaptar ou reproduzir novas situações; o treinamento pode ser muito demorado e exigir um conhecimento técnico do operador e um esforço computacional grande (AL-DAHIDI et al., 2018). Além disso, as RNA geram muitos parâmetros, com isso inviabiliza a interpretação deles.

Assim, existem grandes oportunidades a serem exploradas na utilização da técnica de Redes Neurais Artificiais para aumentar a acurácia das previsões de séries temporais, como estudos que testam diferentes tipos de redes, a utilização de modelos híbridos (ARIMA-ANN), melhores configuração/topologias (camadas, funções de ativação em cada camada, variáveis de entrada, algoritmos etc.). De modo geral, os modelos ARIMA e ARIMAX apresentaram boa performance. Contudo, as RNA conseguiram superar as previsões desses modelos, sendo uma boa alternativa para a modelagem de séries temporais.

## 6 CONCLUSÃO

Apesar das crises econômicas mundiais ao longo dos anos, as exportações dos principais produtos florestais madeireiros são promissoras e tendem a aumentar ao longo dos anos, realçando a sua importância na economia do Brasil.

Os modelos ARIMA, ARIMAX e as Redes Neurais Artificiais (RNA) individuais e gerais foram eficientes na previsão das variáveis relacionadas a exportação de produtos florestais madeireiros, com destaque para as RNA individuais que apresentaram de forma geral maior acurácia na previsão das séries temporais. As RNA que previram as séries temporais de forma simultânea também apresentaram boa performance, sendo uma alternativa para reduzir o tempo de modelagem quando o objetivo não é apenas a precisão das previsões.

As topologias de RNA com a função de ativação exponencial, algoritmo Rprop e número de neurônios entre 16–30 são indicadas para previsão das séries temporais para os dois grupos de produtos florestais madeireiros. Estudos que utilizem outras configurações de RNA e outras técnicas podem ser realizados com o intuito de aumentar a performance das previsões das séries temporais.

Estudos futuros podem ser conduzidos para melhorar a acurácia das previsões, como a utilização dos modelos da família ARIMA de forma híbrida com as RNA ou com outras técnicas de aprendizado de máquina.

## REFERÊNCIAS

- AHMED, R.; VVEINHARDT, J.; AHMAD, N.; STREIMIKIENE, D. **Karachi Inter-Bank Offered Rate (KIBOR) Forecasting: Box-Jenkins (ARIMA) Testing Approach**. Rochester, NY: Social Science Research Network, 2017. Disponível em: <<https://papers.ssrn.com/abstract=3030109>>. Acesso em: 25 set. 2021.
- AKYÜZ, İ. Future projection and the sales of industrial wood in Turkey: artificial neural networks. **Turk J Agric For**, p. 10, 2009.
- AL-DAHIDI, S.; AYADI, O.; ADEEB, J.; ALRBAI, M.; QAWASMEH, B. R. Extreme Learning Machines for Solar Photovoltaic Power Predictions. **Energies**, v. 11, n. 10, p. 2725, 2018.
- ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS. **Anuário estatístico da ABRAF 2009..** Disponível em: <<http://www.bibliotecaflorestal.ufv.br/handle/123456789/3905>>.
- BAKAY, M. S.; AĞBULUT, Ü. Electricity production based forecasting of greenhouse gas emissions in Turkey with deep learning, support vector machine and artificial neural network algorithms. **Journal of Cleaner Production**, v. 285, p. 125324, 2021.
- BANAŚ, J.; UTRNIK-BANAŚ, K. Evaluating a seasonal autoregressive moving average model with an exogenous variable for short-term timber price forecasting. **Forest Policy and Economics**, v. 131, p. 102564, 2021.
- BERGMEIR, C.; BENITEZ, J. M. Neural networks in R using the Stuttgart Neural Network Simulator: RSNNS. **Journal of Statistical Software**, v. 46, n. 7, p. 1–26, 2012.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de Redes Neurais Artificiais para Estimção do Volume de Árvores. **Revista Ciência da Madeira - RCM**, v. 5, n. 1, p. 58–67, 2014.
- BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis, Forecasting and Control**. San Francisco: Holden-Day, 1970.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. *Time Series Analysis*. n. 5, p. 709, 2015.

BRAGA, M. de B.; FERNANDES, R. da S.; SOUZA, G. N. De; ROCHA, J. E. C. Da; DOLÁCIO, C. J. F.; TAVARES JÚNIOR, I. da S.; PINHEIRO, R. R.; NORONHA, F. N.; RODRIGUES, L. L. S.; RAMOS, R. T. J.; CARNEIRO, A. R.; BRITO, S. R. De; DINIZ, H. A. C.; BOTELHO, M. do N.; VALLINOTO, A. C. R. Artificial neural networks for short-term forecasting of cases, deaths, and hospital beds occupancy in the COVID-19 pandemic at the Brazilian Amazon. **PLOS ONE**, v. 16, n. 3, p. e0248161, 2021.

CARTA, S.; MEDDA, A.; PILI, A.; REFORGIATO RECUPERO, D.; SAIA, R. Forecasting E-Commerce Products Prices by Combining an Autoregressive Integrated Moving Average (ARIMA) Model and Google Trends Data. **Future Internet**, v. 11, n. 1, p. 5, 2019.

CASTELLANO-MÉNDEZ, M.; GONZÁLEZ-MANTEIGA, W.; FEBRERO-BANDE, M.; MANUEL PRADA-SÁNCHEZ, J.; LOZANO-CALDERÓN, R. Modelling of the monthly and daily behaviour of the runoff of the Xallas river using Box–Jenkins and neural networks methods. **Journal of Hydrology**, v. 296, n. 1–4, p. 38–58, 2004.

CIPRA, T. **Time Series in Economics and Finance**. Cham: Springer International Publishing, 2020. Disponível em: <<http://link.springer.com/10.1007/978-3-030-46347-2>>. Acesso em: 21 set. 2021.

COELHO JUNIOR, L. M.; SELVATTI, T. D. S.; ALENCAR, F. V.; SANTOS JÚNIOR, E. P.; BORGES, L. A. C.; REZENDE, J. L. P. Global concentration of pulp exports. **Floresta**, v. 48, n. 4, p. 443, 2018.

DAVE, E.; LEONARDO, A.; JEANICE, M.; HANAFIAH, N. Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM. **Procedia Computer Science**, v. 179, p. 480–487, 2021.

FANOODI, B.; MALMIR, B.; JAHANTIGH, F. F. Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models. **Computers in Biology and Medicine**, v. 113, p. 103415, 2019.

FAO (ED.). **Innovation in family farming**. Rome: FAO, 2014.

FAO (ED.). **Climate change, agriculture and food security**. Rome: FAO, 2016.

FAO (ED.). **Meeting the sustainable development goals**. Rome: FAO, 2018.

GAIRAA, K.; KHELLAF, A.; MESSLEM, Y.; CHELLALI, F. Estimation of the daily global solar radiation based on Box–Jenkins and ANN models: A combined approach. **Renewable and Sustainable Energy Reviews**, v. 57, p. 238–249, 2016.

GORGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B.; CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v. 38, n. 2, p. 289–295, 2014.

GULERYUZ, D. Forecasting outbreak of COVID-19 in Turkey; Comparison of Box–Jenkins, Brown’s exponential smoothing and long short-term memory models. **Process Safety and Environmental Protection**, v. 149, p. 927–935, 2021.

HASSAN, J. ARIMA and regression models for prediction of daily and monthly clearness index. **Renewable Energy**, v. 68, p. 421–427, 2014.

HAYKIN, S. S.; HAYKIN, S. S. **Neural networks and learning machines**. 3rd ed ed. New York: Prentice Hall, 2009.

HEATON, J. **Programming neural networks with Encog3 in Java**. 2. ed. St. Louis, USA: Heaton Research, Inc., 2011.

HYNDMAN, R.; ATHANASOPOULOS, G.; BERGMEIR, C.; CACERES, G.; CHHAY, L.; O’HARA-WILD, M.; PETROPOULOS, F.; RAZBASH, S.; WANG, E.; YASMEEN, F. **\_forecast: Forecasting functions for time series and linear models\_**. R package version 8.15.. Disponível em: <<https://pkg.robjhyndman.com/forecast/>>. Acesso em: 10 ago. 2021.

INDÚSTRIA BRASILEIRA DE ÁRVORES. **Relatório IBÁ 2020**.. Disponível em: <<https://iba.org/datafiles/publicacoes/relatorios/relatorio-iba-2020.pdf>>. Acesso em: 17 jul. 2021.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção da extração vegetal e da silvicultura 2019**. Brasília. Disponível em: <[https://biblioteca.ibge.gov.br/visualizacao/periodicos/74/pevs\\_2019\\_v34\\_informativo.pdf](https://biblioteca.ibge.gov.br/visualizacao/periodicos/74/pevs_2019_v34_informativo.pdf)>.

KARLIK, B.; OLGAC, A. V. Performance analysis of various activation functions in generalized mlp architectures of neural networks. **International Journal of Artificial Intelligence and Expert Systems**, v. 1, n. 4, p. 12, 2011.

KOUTROUMANIDIS, T.; IOANNOU, K.; ARABATZIS, G. Predicting fuelwood prices in Greece with the use of ARIMA models, artificial neural networks and a hybrid ARIMA–ANN model. **Energy Policy**, v. 37, n. 9, p. 3627–3634, 2009.

KURT, R. Determination of the most appropriate statistical method for estimating the production values of medium density fiberboard. **BioResources**, p. 17, 2019.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015.

MEILLER, M. F. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. v. 6, n. 4, p. 525–533, 1993.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. **Florestas do Brasil em resumo: 2019**. Brasília: Serviço Florestal Brasileiro, 2019. . Acesso em: 20 ago. 2021.

MOHAMMED, M. A.; NAJI, T. A. H.; ABDULJABBAR, H. M. The effect of the activation functions on the classification accuracy of satellite image by artificial neural network. **Energy Procedia**, Technologies and Materials for Renewable Energy, Environment and Sustainability (TMREES). v. 157, Technologies and Materials for Renewable Energy, Environment and Sustainability (TMREES), p. 164–170, 2019.

OHYVER, M.; PUDJIHASTUTI, H. Arima model for forecasting the price of medium quality rice to anticipate price fluctuations. **Procedia Computer Science**, v. 135, p. 707–711, 2018.

PFAFF, B. **Analysis of integrated and cointegrated time series with R**. 2<sup>a</sup> ed. New York: Springer, 2008.

QONITA, A.; PERTIWI, A. G.; WIDIYANINGTYAS, T. Prediction of rupiah against US dollar by using ARIMA. In: 2017 4TH INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING, COMPUTER SCIENCE AND INFORMATICS (EECSI)

2017, **Anais...** . In: 2017 4TH INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING, COMPUTER SCIENCE AND INFORMATICS (EECSI).

R CORE TEAM (2021). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

SALMAN, A. G.; KANIGORO, B. Visibility forecasting using autoregressive integrated moving average (ARIMA) models. **Procedia Computer Science**, v. 179, p. 252–259, 2021.

SELVAMUTHU, D.; KUMAR, V.; MISHRA, A. Indian stock market prediction using artificial neural networks on tick data. **Financial Innovation**, v. 5, n. 1, p. 16, 2019.

SERVIÇO FLORESTAL BRASILEIRO. **Sistema Nacional de Informações Florestais – SNIF**. Brasília. Disponível em: <<http://snif.florestal.gov.br/pt-br/>>.

SHADAB, A.; SAID, S.; AHMAD, S. Box–Jenkins multiplicative ARIMA modeling for prediction of solar radiation: a case study. **International Journal of Energy and Water Resources**, v. 3, n. 4, p. 305–318, 2019.

SHRESTHA, A.; MAHMOOD, A. Review of Deep Learning Algorithms and Architectures. **IEEE Access**, v. 7, p. 53040–53065, 2019.

SILVA, I. N. Da; HERNANE SPATTI, D.; ANDRADE FLAUZINO, R.; LIBONI, L. H. B.; ALVES, S. F. dos R. **Artificial Neural Networks**. Cham: Springer International Publishing, 2017. Disponível em: <<http://link.springer.com/10.1007/978-3-319-43162-8>>. Acesso em: 25 set. 2021.

SOARES, N. S.; SILVA, M. L. Da; LIMA, J. E. De; CORDEIRO, S. A. Análise de previsões do preço da borracha natural no Brasil. **Scientia Forestalis**, v. 36, n. 80, p. 285–294, 2008.

SOARES, N. S.; SILVA, M. L. Da; REZENDE, J. L. P. De; GOMES, M. F. M. Competitividade da cadeia produtiva da madeira de eucalipto no Brasil. **Revista Árvore**, v. 34, n. 5, p. 917–928, 2010. a.

SOARES, N. S.; SILVA, M. L. Da; REZENDE, J. L. P. De; LIMA, J. E. De; CARVALHO, K. H. A. De. Elaboração de modelo de previsão de preço da madeira de *Eucalyptus* spp. **Cerne**, v. 16, n. 1, p. 41–52, 2010. b.

TAVARES JÚNIOR, I. da S.; TORRES, C. M. M. E.; LEITE, H. G.; CASTRO, N. L. M. De; SOARES, C. P. B.; CASTRO, R. V. O.; FARIAS, A. A. Machine learning: Modeling increment in diameter of individual trees on Atlantic Forest fragments. **Ecological Indicators**, v. 117, p. 106685, 2020.

WUNSCH, A.; LIESCH, T.; BRODA, S. Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (NARX). **Journal of Hydrology**, v. 567, p. 743–758, 2018.

YIP, H.; FAN, H.; CHIANG, Y. Predicting the maintenance cost of construction equipment: Comparison between general regression neural network and Box–Jenkins time series models. **Automation in Construction**, v. 38, p. 30–38, 2014.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, v. 50, p. 159–175, 2003.

ZHANG, G. P.; PATUWO, B. E.; HU, M. Y. A simulation study of artificial neural networks for nonlinear time-series forecasting. **Computers & Operations Research**, v. 28, n. 4, p. 381–396, 2001.

ZHAO, X.; YUE, S. Analysing and forecasting the security in supply-demand management of Chinese forestry enterprises by linear weighted method and artificial neural network. **Enterprise Information Systems**, p. 1–18, 2020.